文章编号:1671-4598(2014)08-2387-04　　中图分类号:TP206.3　　文献标识码:A

基于粒子群算法的诊断策略优化技术

石　翌[1]，胡　鹰[2]，李俊杰[3]，张　强[3]
(1.95856部队，南京　210028；2.94883部队，杭州　310022；3.北京航天测控技术有限公司，北京　100041)

摘要：针对复杂武器装备系统多层次、多功能的特点以及测试性设计这一重大需求，为解决当前普遍采用的诊断策略存在的灵活性差、多故障诊断与不确定性诊断能力弱等问题，提出了一种基于自适应离散粒子群算法的诊断策略优化生成算法；该算法对自适应离散粒子群算法进行改进，引入多样性指标、个体历史最差解、扩散聚合过程和自适应惯性权重等，通过迭代计算得到最优的诊断策略；最后给出了主要步骤，并通过实例验证了算法的可行性。

关键词：测试性设计；诊断策略；粒子群算法

Optimization of Hierarchical Diagnostic Strategy Based on Particle Swarm Algorithm

Shi Yi[1], Hu Ying[2], Li Junjie[3], Zhang Qiang[3]
(1. Troop 95856, Nanjing　210028, China; 2. Troop 94883, Hangzhou　310022, China;
3. Beijing Aerospace Measurement and Control Corporation, Beijing　100041, China)

Abstract: Aiming at the characteristics of complicated equipment of multi-hierarchy, multi-function and design for testability, optimization of hierarchical diagnostic strategy based on self-adaptive discrete particle swarm algorithm is studied in this paper. This algorithm improves the self-adaptive discrete particle swarm algorithm, introduces variety index, the worst solution of individual history, diffusion and polymerization process and self-adaptive inertia weight, then get the optimal diagnostic strategy by iterative computation. Finally, the main procedures are given, and experimental results show that the algorithm can reach an ideal trade-off between accuracy and computational complexity.

Keywords: design for testability; diagnostic strategy; particle swarm algorithm

0　引言

测试性是系统和设备的一种便于测试与诊断的重要设计特性，对现代武器装备及各种复杂系统特别是对电子系统和设备的维修性、可靠性和可用性有很大影响。良好的测试性设计可以提高装备的战备完好性、执行任务的可靠性与安全性，缩短维修时间，降低系统使用保障时间，大大降低装备的全寿命周期费用。

国外最有名的基于多信号模型的测试性建模与分析工具TEAMS（测试性工程和维护系统）生成诊断策略的方法是由Somanath Deb等提出[1]，仅对故障传播建模的一种模型方法。以此为基础，Fang Tu等人发展了复杂系统诊断树算法[2]。同一个相关模型可以对应若干不同的诊断树（测试序列），如何找到最佳测试序列使测试费用达到最小是诊断树自动建造过程中的关键问题，即测试序列问题。该问题已被证明属于NPC类问题[3]，解决的方法目前主要有动态规划（DP）算法和基于与/或树的启发式搜索（AO*）算法[4]。在国内，北京航空航天大学的石君友等人对诊断策略进行了较深入的研究[5]。从推理模型看，主要有故障树、决策树、马尔柯夫可靠性模型、信息模型、有向图模型、概率因果网络、神经网络、规则推理模型。所有方法都遵守“最小代价”原则，具体目标都一致：故障的发现率和定位率最高，所用诊断时间最短，搜索成本最低。这些方法在一定程度上满足了故障诊断策略优化的要求，在设备故障诊断与维修中取得了广泛的应用。但从总体上看，这些决策模型和方法存在或多或少的局限，主要表现在：不确定性处理能力有待提高、多源信息表达与融合能力相对较弱，灵活性差。同时无法及时利用诊断经验，对环境适应性不好，虚警和漏检率高。针对上述问题，本文首先对层次诊断问题进行描述，然后采用改进的离散粒子群算法对诊断策略进行优化。该方法可根据故障隔离精度的要求生成相应的最优诊断策略，且平均测试费用较低。

1　诊断策略优化问题的数学描述

分层诊断策略问题的可由五元组（F，p，T，c，B）定义[6]，其中：

1）$F=\{f_0,f_1,\cdots,f_m\}$为满足当前诊断限制条件的模块全部故障模式集，其中f_0表示诊断对象无故障结论，f_i表示只有第i个故障发生。

2）$P=\{P(f_0),P(f_1),\cdots,P(f_m)\}$为模块故障模式概率分布集合，其中$P(f_0)$表诊断对象无故障结论的概率，$P(f_i)$表示仅有故障$f_i$发生的概率，由下式求解：

$$P(f_i)=\frac{1}{1+\sum_{k=1}^{m}\frac{\lambda_k}{(1-\lambda_k)}} \tag{1}$$

$$P(f_i)=\frac{\frac{\lambda_i}{(1-\lambda_i)}}{1+\sum_{k=1}^{m}\frac{\lambda_k}{(1-\lambda_k)}},i\neq 0 \tag{2}$$

其中：λ_k为故障f_k的常数故障率。

3）$T=\{t_1,t_2\cdots,t_n\}$为满足当前诊断限制条件的可用测试集，规定每个测试都是二值输出，而且测试结果都是可靠的。

4）$C=\{c_1,c_2\cdots,c_n\}$为测试执行费用集合，表示测试执行的时间、人力等的测度，规定测试费用为常量，即不依赖于测试顺序。

5）B为一个$(m+1)\times n$维的故障模式诊断结论-测试

收稿日期：2014-05-24；　**修回日期**：2014-06-15。

作者简介：石　翌(1978-)，男，江苏本皋人，工程师，主要从事HKDY综合保障研究、导弹测试技术方向的研究及技术开发。

相关矩阵，表示测试与诊断结论的逻辑关系，其元素定义为 $b_{ij}=ft_{ij}, \forall i\neq 0, b_{0j}=0, \forall j$。

参考 Pattipati 等人提出的平均测试费用最少的优化目标函数，分层诊断的优化目标函数定义为：

$$D_{opt}=\min_{D}\left\{\sum P(x_i)\left(\sum_{k=1}^{|D_{(i)}|}c_{D_{(i)}|k|}\right)\right\} \tag{3}$$

式中，D_{opt} 为满足隔离精度要求，不模糊地隔离任意模块、且平均测试费用最少的诊断策略；$D_{(i)}$ 为诊断树 D 中隔离出叶子节点 x_i 的测试序列，$|D_{(i)}|$ 为该序列的长度，$c_{D_{(i)}|k|}$ 为序列 $D_{(i)}$ 中第 k 个测试的费用，$P(x_i)$ 为叶子节点 x_i 的概率，若 x_i 对应于某单个诊断结论 U_i，则有 $P(x_i)=\sum_{f_j\in x_i}P(f_j)$。

2 基于粒子群算法的诊断策略优化

2.1 粒子群算法基本理论

2.1.1 标准粒子群算法

PSO 算法的基本思想是随机初始化一群没有体积没有质量的粒子，将每个粒子视为优化问题的一个可行解，粒子的好坏由一个事先设定的适应度函数来确定[7]。每个粒子将在可行解空间中运动，并由一个速度变量决定其方向和距离。通常粒子将追随当前的最优粒子，并经逐代搜索最后得到最优解。在每一代中，粒子将跟踪两个极值：一个是粒子本身迄今为止找到的最优解 p_{best}，另一个是整个群体迄今为止找到的最优解 g_{best}[8]。

假设一个由 M 个粒子组成的群体在 S 维的搜索空间以一定的速度飞行。粒子 i 在 t 时刻的状态属性设置如下：

位置：$\overrightarrow{x_i}=(x_{i1},x_{i2},\cdots,x_{iS})$

其中：$x_{iS}\in[L_d,U_d]$，L_d，U_d 分别为搜索空间的下限和上限；

速度：$\overrightarrow{V}=(V_{i1},V_{i2},\cdots,V_{iS})$

其中：$V_{iS}\in[V_{\min,d},V_{\max,d}]$，$V_{min}$、$V_{max}$ 分别为最小和最大速度；

个体最优位置：$\overrightarrow{P_{is}}=(P_{i1},P_{i2},\cdots,P_{iS})$；

全局最优位置：$\overrightarrow{P_{gs}}=(P_{g1},P_{g2},\cdots,P_{gS})$；

其中：$1\leqslant d\leqslant D, 1\leqslant i\leqslant M$。

则粒子在 $t+1$ 时刻的位置通过以式（4）、（5）更新获得：

$$v_{is}(t+1)=v_{is}(t)+c_1r_{1s}(t)(p_{is}(t)-x_{is}(t))+c_2r_{2s}(t)(p_{gs}(t)-x_{is}(t)) \tag{4}$$

$$x_{is}(t+1)=x_{is}(t)+v_{is}(t+1) \tag{5}$$

式中，r_1 和 r_2 为均匀分布在［0，1］区间的随机数；c_1，c_2 称为学习因子。

式（5）主要由三部分组成：第一部分为粒子先前速度的继承，表示粒子对当前自身运动状态的信任，依据自身的速度进行惯性运动；第二部分为“认知”部分，表示粒子本身的思考，即综合考虑自身以往的经历从而实现对下一步行为的决策，这种行为决策便是“认知”，反映了一个增强学习过程；第三部分为“社会”部分，表示粒子间的信息共享与相互合作。在搜索过程中粒子一方面记住它们自己的经验，同时考虑其同伴的经验。当单个粒子察觉同伴经验较好时，它将进行适应性的调整，寻求一致认知过程。

标准 PSO 算法的实现步骤如下：

1）初始化。设定 PSO 算法中涉及的各类参数：搜索空间的上限 U_d 和下限 L_d，学习因子 c_1、c_2，算法最大迭代次数 $T_{\max}$ 或收敛精度 ξ，粒子速度范围［$V_{\min}$，$V_{\max}$］；随机初始化搜索点的位置 X_i 及其速度 V_i，设当前位置即为每个粒子的 p_{best}，从个体极值找出全局极值，记录该最好值的粒子序号 g 及其位置 g_{best}。

2）评价每一个粒子。计算粒子的适应值，如果好于该粒子当前的个体极值，则将 p_{best} 设置为该粒子的位置，且更新个体极值。如果所有粒子的个体极值中最好的都好于当前的全局极值，则将 g_{best} 设置为该粒子的位置，更新全局极值及其序号 g。

3）粒子的状态更新。用式对每一个粒子的速度和位置进行更新。如果 $V_i>V_{\max}$ 将其置为 $V_{\max}$，如果 $V_i<V_{\min}$ 则将其置为 $V_{\min}$。

4）检验是否符合终止条件。如果当前的迭代次数达到了预先设定的最大次数 $T_{\max}$，或最终结果小于预定收敛精度 ξ 要求，则停止迭代，输出最优解，否则转到步骤 2）。

Y. Shi 等人通过一个惯性权重 ω 来协调 PSO 算法的全局和局部寻优能力[9]。具体做法是将基本 PSO 的速度方程修改为如下公式，而位置方程保持不变：

$$v_{is}(t+1)=\omega\cdot v_{is}(t)+c_1r_{1s}(t)(p_{is}(t)-x_{is}(t))+c_2r_{2s}(t)(p_{gs}(t)-x_{is}(t)) \tag{6}$$

在式中 ω 为非负数，称为惯性权重，其大小决定了粒子对当前速度继承的多少，选择一个合适的 ω 有助于 PSO 均衡它的搜索能力与开发能力。较大的惯性权重有利于展开全局寻优，而较小的惯性权重则有利于局部寻优。因此，如果在迭代计算过程中呈线性递减惯性权重，则 PSO 算法在开始时具有良好的全局搜索能力，能够迅速定位到接近全局最优点的区域，而在后期具有良好的局部搜索性能，能够精确地得到全局最优解。Y. Shi 等经过反复实验后，建议采用从 0.9 线性递减到 0.4 的策略，通常会取得比较好的算法性能。线性递减公式如下：

$$\omega=\omega_{\text{start}}-\frac{\omega_{\text{start}}-\omega_{\text{end}}}{t_{\max}}\times t \tag{7}$$

式中，$t_{\max}$ 为最大迭代次数，t 为当前迭代次数，ω_{start} 为初始惯性权重，ω_{end} 为终止惯性权重。

2.1.2 基于置换的离散粒子群算法

由于 PSO 算法运算速度快，可调参数少，PSO 算法及其改进算法已经在许多领域得到了成功应用。但诊断策略优化问题是一个典型的具有 AllDifferent 约束的离散问题，无法用标准的连续粒子群算法求解。

Rameshkumar 等人提出了基于置换的离散粒子群算法[9]是目前应用最多的适用于离散问题的粒子群算法。置换离散粒子群算法并不引入新的元素只是交换位置中元素的顺序，所以只要构造粒子初始位置时保证 AllDifferent 约束，那么在运算过程中，该约束始终满足，适用于解带有 AllDifferent 约束的离散问题，并有效地减少计算 AllDifferent 约束的费用，提高算法的运行效率[10]。

置换离散粒子群算法对速度和位置的相关公式都进行了变化，定义如下：

“位置＋位置”：给定两个粒子的位置 $X_i=\{X_{i1},X_{i2},\cdots,X_{\text{im}}\}$，$X_j=\{x_{j1},x_{j2},\cdots,x_{jm}\}$，则 X_i+X_j 定义如下：

$$X_i+X_j=U_{k=1}^{m}E(x_{ik},x_{jk}) \tag{8}$$

其中：$E(x_{ik},x_{jk})=\begin{cases}\{x_{ik}\}, & \text{if } x_{ik}=X_{jk}\\ \varnothing, & \text{if } x_{ik}=x_{jk}\end{cases}$

“位置－位置”：假定两个粒子的位置，$X_i=\{x_{i1}, x_{i2}, \cdots, x_{im}\}$，$X_j=\{x_{j1}, x_{j2}, \cdots, x_{jm}\}$，则 X_i-X_j 将得到新的速度。

例如：$A=(1, 2, 3, 4, 5)$，$B=(2, 3, 1, 4, 5)$，由于 $A(1)=1$、$B(1)=2$、$A(1)\neq B(1)$，第一个置换子为 $(A(1), B(1))$、即 $(1, 2)$，更新 $B=B+(1, 2)=(1, 3, 2, 4, 5)$；由于 $A(2)=2$、$B(2)=3$ 和 $A(2)\neq B(2)$，第二个置换子为 $(A(2), B(2))$ 即 $(2, 3)$，更新 $B=B+(2, 3)=(1, 2, 3, 4, 5)$；因为 $B(3)=A(3)$、$B(4)=A(4)$ 和 $B(5)=A(5)$，即 $B=A$，最后得到 $A-B$ 的置换序列为 $((1, 2), (2, 3))$。即 $A-B=V$，则 $A=B+V$。

“位置＋速度”：给定粒子位置 $X_i=\{x_{i1}, x_{i2}, \cdots, x_{im}\}$ 和速度 $V_j=\{(x_{j1}, x_{j2}), (x_{j3}, x_{j4}), \cdots, (x_{jm-1}, x_{jm})\}$，则 X_i+X_j 表示将一组置换序列依次作用于粒子位置并得到新的位置。

例如：$A=(2, 1, 3, 4, 5)+(2, 5)=(5, 1, 3, 4, 2)$。

“实数×速度”：将速度截取一定长度，等到新的速度，其中，限定实数 $c\in(0, 1)$。假设速度 V 包含 k 个置换序列，则乘法操作将对速度进行截取，使得新的速度的长度等于 $|ck|$。

例如 $c=0.6$，$V=((1, 2), (2, 3), (3, 4), (4, 5), (5, 2))$，则运算的结果是截取速度的前 3 个置换子，得到 $V=((1, 2), (2, 3), (3, 4))$。

“速度＋速度”：给定粒子的速度 $V_i=\{(x_{i1}, x_{i2}), (x_{i3}, x_{i4}), \cdots, (x_{im-1}, x_{im})\}$，$V_i=\{(x_{i1}, x_{i2}), (x_{i3}, x_{i4}), \cdots, (x_{im-1}, x_{im})\}$，则 V_i+V_j 将通过把 V_j 的置换序列直接加到 V_i 置换序列的列表末尾得到新的速度。

例如：$V_1=((1, 2), (2, 3))$，$V_2=((3, 4), (4, 5), (5, 2))$，则 $V_1+V_2=((1, 2), (2, 3), (3, 4), (4, 5), (5, 2))$。

2.2　自适应离散粒子群算法

与连续粒子群算法一样，离散粒子群算法也存在早熟收敛问题，这主要是由于搜索过程中粒子间快速的信息流动使粒子聚集在一起，群体多样性快速下降，最终导致群体适应度停滞，陷入局部最优解。所以本文采用了一种自适应离散粒子群算法[11]，引入了多样性指标、个体历史最差解、扩散聚合过程和自适应惯性权重来克服早熟收敛问题。求解过程如下：

2.2.1　粒子初始化及编码

在该算法中，用粒子的位置表示最终的测试排序。首先对模型中的故障模糊组和冗余测试进行处理，即将故障模糊组中的全部故障视为一个故障，将冗余测试删掉，只保留测试费用最小的一个，并将可用测试从 1 开始进行编号，然后直接采用编号对粒子位置进行编码。例如 n 个测试的诊断策略优化问题，则将测试分别编号为 $1\sim n$，进而确定了粒子位置的维数为 n，分别为 $1\sim n$ 的不同整数。在初始化时，定义种群大小为 S，搜索空间的上限 U_d 为 n 和下限 L_d 为 1，算法最大迭代次数 $T_{\max}$，适应值阈值 d_{low} 和 d_{high}，进而随机初始化每个粒子的位置 X_i，初始速度 V_i 为 0。

2.2.2　适应值计算

按照之前的分析，采用公式对每个粒子的适应值进行计算，并更新每个粒子的 $P_{k,\text{best}}$ 和 $P_{k,\text{worst}}$，进而从个体极值找出全局极值，记录最好值的粒子序号 g 及其位置 G_{best}。在计算适应值之前，需要根据粒子编码重新构造与或树，若某一分枝上的测试不能对模糊组进行隔离，则在该分枝上将该测试删除，进而对下一个测试进行处理。

2.2.3　多样性计算

多样性指标 div 根据下面公式定义：

$$div=D(S)=\frac{2}{1+e^{-\frac{\sum_{j=1}^{N}\left|\bigcup_{i=1}^{|S|}\{p_{ij}\}\right|}{N\cdot|S|}}}-1 \tag{9}$$

其中：$|S|$ 表示群体规模，N 问题的维度，p_{ij} 表示第 i 个粒子当前位置的第 j 个成分。可以看出此多样性准则不依赖于群体规模及问题的维度。当前群体的多样性指标取值于 $[0, 1]$ 之间并随群体中的个体之间的差异量单调增加。

2.2.4　速度、位置更新

当群体多样性低于指定的阈值 d_{low} 时，执行扩散过程，使粒子偏离个体最差解及当前群体最优解，搜索未曾到达过的搜索区域，直到群体的多样性高于指定的阈值 d_{high}，执行聚合过程，使个体向当前群体最优及个体最优解运动。为了进一步提高算法的性能，在算法执行的不同阶段，使惯性权重随迭代次数动态自适应变化。

算法中粒子的速度更新公式和位置更新公式定义如下：

速度更新公式：

聚合过程：

$$V_k^{t+1}=\omega\times V_k^t+c_1(P_{k,\text{best}}-P_{k,\text{current}})+c_2(G_{\text{best}}-P_{k,\text{current}}) \tag{10}$$

扩散过程：

$$V_k^{t+1}=\omega\times V_k^t+c_1(P_{k,\text{best}}-P_{k,\text{worst}})+c_2(P_{k,\text{current}}-G_{\text{best}}) \tag{11}$$

位置更新公式：

$$P_k^{t+1}=P_k^t+V_k^{t+1} \tag{12}$$

可以看出，聚合过程与基本的粒子群公式类似，粒子之间共享当前较优解的信息，粒子向最有解方向聚合；而在扩散过程中，粒子之间共享个体最差及当前群体最优解信息，粒子向远离这些位置的方向运动，搜索未曾到达的潜在最优解区域，增加群体多样性。

在公式（10）～（12）中，我们采用一种非线性自适应策略，使惯性权重 ω 在算法运行过程中动态变化。

$$\omega=f(t)=\begin{cases}\left\{\dfrac{(t_{\max}-t)^n}{(t_{\max}-t_{sw})^n}\right\}(\omega_{sw}-\omega_{\text{final}})+\omega_{\text{final}}, & attract=true\\ C, & attract=false\end{cases} \tag{13}$$

其中：$t_{\max}$ 为最大迭代次数，t 为当前迭代次数，ω_{initial} 为初始权重，ω_{final} 运行结束时的最终权重，C 为常量其值略小于 ω_{initial}，算法开始运行时 $\omega_{sw}=\omega_{\text{initial}}$，当执行扩散过程之后 $\omega_{sw}=C$。t_{sw} 的值等于算法中扩散过程停止，聚合过程开始时刻的迭代次数，其初始值为 0。通过调节参数 n 来动态平衡全局搜索及局部搜索能力。由图可以看出，当 $n=1$ 时，ω 呈线性变化；当 $n>1$ 时算法倾向于全局搜索；$n<1$ 时算法倾向于局部搜索。在算法中，当最大迭代次数与当前迭代次数的差小于预先给定的值 M 时，执行扩散过程并令参数 n 的取值小于 1.0，其他情况 n 的取值大于 1.0。本文试验中 n 的取值分别为 0.6 和 1.6。

表 1　阿波罗飞船测试与故障依赖关系

故障模式	测试																																	故障概率
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	32	33	34	35	36	
1	0	0	0	0	0	0	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	0	1	0.001 85
2	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	0.009 23
3	0	0	0	0	0	0	0	0	0	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	1	0	0	0	0	0	0	0	0	0	1	0.185 00
4	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0.001 85
5	0	0	0	1	0	0	1	0	1	1	1	0	1	1	1	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	0	1	0	1	1	0.001 85
6	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	0	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	0.009 23
7	1	0	0	1	0	0	1	0	0	1	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	1	0	0	1	0	0	1	0	0	1	0.001 85
8	1	0	1	1	0	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	1	0	1	1	0	1	0	0	1	1	0.009 23
9	1	0	1	1	0	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	1	0	1	0	1	0	0	1	1	0.185 00
10	0	0	0	1	0	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	1	0	0	0	1	1	0.185 00
11	0	0	0	0	0	0	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	0	0	1	0	1	0.185 00
12	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0.001 85
13	0	0	0	1	1	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	0	0	0	1	1	0.009 23
14	1	0	1	1	0	1	1	0	1	1	1	1	1	1	1	0	0	0	0	1	0	1	1	1	1	0	0	1	0	1	1	1	1	1	1	1	0.185 00
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0.009 23
16	0	0	0	0	0	0	0	0	0	1	1	1	1	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0.001 85
17	0	0	0	0	0	0	1	1	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	0	0	0	0	1	0	1	0.009 23
18	1	1	1	1	0	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	1	0	1	0	0	1	1	0.001 85
19	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0.001 85
20	0	0	0	1	0	1	1	0	1	1	1	0	1	0	0	0	0	0	0	1	0	1	1	1	1	0	0	0	0	1	1	1	0	0	1	1	0.001 85
21	1	0	0	1	0	0	1	0	0	1	1	0	0	1	0	0	1	0	0	1	0	0	1	0	1	0	1	0	0	1	0	0	1	0	0	1	0.001 85
22	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0.001 85

2.2.5　检验是否满足结束条件

如果当前的迭代次数达到了预先设定的最大次数 T_{max}，或最终结果小于预定收敛精度 ξ 要求，则停止迭代，输出最优解，否则转到步骤 2。

2.3　算法性能对比

为验证算法的有效性，分别采用信息增益最大算法、AO＊算法和本文提出的算法对文献［12］提供的阿波罗飞船发射前测试模型进行诊断策略优化。在该模型中可选测试项目共 36 个，可能的故障共 22 个，每项测试的费用相同均为 1，测试与故障的依赖关系及故障概率如表 1 所示。

本文算法计算得到的诊断树如图 1 所示，信息增益最大算法、AO＊算法参见文献［8，10］。

3 种算法所使用的计算时间和得到的平均测试费用如表 2 所示。

表 2　算法比较结果

结果统计	信息增益最大算法	AO＊算法	自适应粒子群算法
平均测试费用	3.71	3.39	3.42
计算时间/s	0.000 001	0.56	0.004 9

从计算结果来看，本文提出的自适应离散粒子群算法在结果优化上优于信息增益最大算法，计算时间也小于 AO＊算法，具有工程应用价值。

3　结论

本文研究了基于粒子群的诊断策略优化技术，提出了一种基于自适应离散粒子群算法的诊断策略优化生成方法。试验结果表明，该方法可以根据故障隔离精度的要求有效实现故障快速检测与隔离，且平均测试费用较低，对于复杂装备的测试性设计和故障诊断具有实际应用价值。

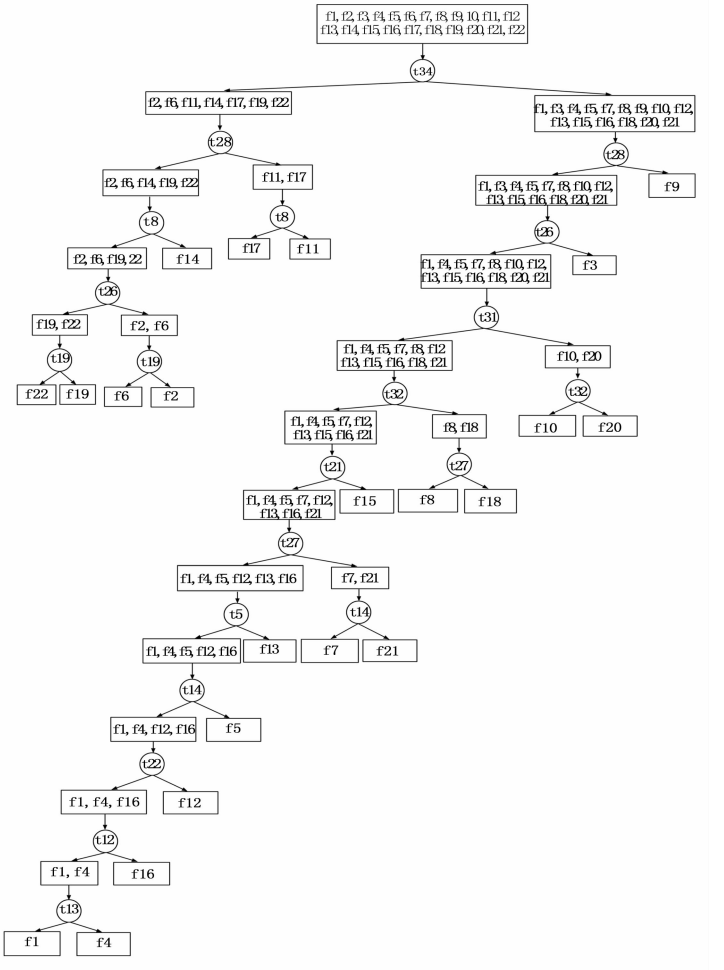

图 1　诊断策略

（下转第 2395 页）

此外，实验还比较了该算法不同小波基和不同可区分度量在相同识别特征矢量条件下的故障识别率，分类器均采用支持向量机。具体实验结果见表 3 和表 4。

表 3　采用不同小波基的识别率

小波基	分类准确率/(%)				总识别率/(%)
	健康轴承	0.18 mm 孔洞	0.36 mm 孔洞	0.53 mm 孔洞	
Bior5.5	100	95	85	100	95.00
Db10	100	90	85	100	93.75
rBio1.3	100	90	95	100	96.25

表 4　采用不同可区分度量方法的识别率

可区分度量	总识别率/(%)
D_1	93.75
D_2	93.75
D_1&D_2	96.25

从表 3 中可以看出，使用 rBio1.3 小波即本实验中最适合该型号轴承信号的分析小波作为基小波的方法比使用其他小波基函数时获得了更高的分类准确率。另一方面，表 4 的结果表明，采用结合两种可区分度量的方法相比采用单一可区分度量的方法提高了分类准确性。该结果表明，本文提出的定量小波选取和改进 LDB 算法结合的方法对复杂多类问题的分类具有良好的分析效果。

6　结论

本文通过对实际采集的不同故障类型下的轴承振动信号的实验分析结果表明，采用定量小波选取和改进局域判别基算法的故障诊断方法可以有效识别滚动轴承的故障类型。此外，从两个对照实验的实验结果可知，分别使用定量基小波选取和多种可区分度量的改进 LDB 算法均提高了分类的准确率，体现了定量小波基选取和多种可区分度量的改进 LDB 算法的有效性。

参考文献：

[1] 王移芝，罗四维. 大学计算机基础教程 [M]. 北京：高等教育出版社，2004.

[2] Marwa C, Mohamad K, Jacques D. Methodology of wavelet packet selection for event detection [J]. Signal Processing, 2006, 86 (16): 3826.

[3] Wu Y, Du R. Feature extraction and assessment using wavelet packets for monitoring of machining processes [J]. Mechanical System and Signal Process, 1996, 10 (1): 29 - 53.

[4] 冯登国. 计算机通信网络安全 [M]. 北京：清华大学出版社，2007.

[5] 孙凤宏. 探索未来计算机技术发展与应用 [J]. 青海统计，2007，(11).

[6] He Q, Yan R, Gao R. Wavelet packet base selection for gearbox defect severity classification [A]. Prognostics and System Health Management Conference [C]. Macao, 2010.

[7] Wu Y H, Shan M X, Qian Y N, et al. Aeroengine rub－impact fault diagnosis based on wavelet packet transform and the local discriminate bases [J]. Applied Mechanics and Materials, 2012, 216 - 228: 740 - 744.

[8] Umapathy K, Krishnan S, Rao R K. Audio signal feature extraction and classification using local discriminant bases [J]. Speech & Language Processing, 2007, 15: 1236 - 1246.

[9] Incea N F, Tewfik A H, Arica S. Extraction subject－specific motor imagery time－frequency patterns for single trial EEG classification [J]. Computers in Biology and Medicine, 2007, 37: 499 - 508.

[10] Wang G, Wang Z Z, Chen W T, et al. Classification of surface EMG signals using optimal wavelet packet method based on Davies－Bouldin criterion [J]. Med. Bio. Eng. Comput., 2006, 44: 865 - 872.

[11] Yen G G, Leong W F. Fault classification on vibration data with wavelet based feature selection scheme [J]. ISA Transactions, 2006, 45: 141 - 151.

(上接第 2390 页)

参考文献：

[1] Deb S, Pattipati K R, Raghavan V, et al. Multi－signal flow graphs: a Novel approach for system testability analysis and fault diagnosis [A]. Proc. IEEE AUTOTESTCON [C]. 1994: 361 - 373.

[2] Tu F, Pattipati K R. Rollout strategies for sequential fault diagnosis [J]. IEEE Transactions on Systems, Man, and Cybernetics. 2003, 33 (1): 86 - 99.

[3] Pattipati K R, Alexandridis M G. Application of Heuristic Search an Information Theory to Sequential Fault Diagnosis [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1990, 20 (4): 872 - 886.

[4] 高　磊，吕振中，景小宁. 飞机实时测试序列生成算法研究及仿真 [J]. 计算机工程与应用，2006，(9)：228 - 232.

[5] 石君友，田　仲. 故障诊断策略的优化方法 [J]. 航空学报，2003，24 (3)：212 - 215.

[6] 陈刚勇. 复杂系统分层诊断策略优化技术研究 [D]. 长沙：国防科技大学，2008.

[7] 李　丽，牛　奔. 粒子群优化算法 [M]. 北京：冶金工业出版社，2009.

[8] Kennedy J, Eberhart R C. Particle swarm optimization [A]. Proceedings of the IEEE International Joint Conference on Neural Networks [C]. Piscataway, NJ: IEEE Service Center, IEEE Press, 1995: 1942 - 1948.

[9] Shi Y, Eberhart R C. A modified particle swarm optimizer [A]. Proceedings of the IEEE World Congress on Computational Intelligence [C]. 1998: 69 - 73.

[10] Rameshkumar K, Suresh R K, Mohanasundaram K M. Discrete particle swarm optimization (DPSO) algorithm for permutation flowshop scheduling to minimize makspan [A]. Proc. ICNC 2005, LNCS 3612 [C], 2005: 572 - 581.

[11] 张长胜，孙吉贵，欧阳丹彤. 一种自适应离散粒子群算法及其应用研究 [J]. 电子学报，2009，37 (2)：299 - 303.

[12] Johnson R A. An information theory approach to diagnosis [A]. Proceedings of the 6th Annual Conference on Reliability and Quality Control [C], 1960: 102.