

# 基于蚁群优化算法的精密伺服转台故障诊断方法

甄子洋<sup>1</sup> 王道波<sup>1</sup> 王志胜<sup>1</sup>

**摘要** 提出了一种基于蚁群优化算法的精密伺服转台故障诊断方法. 根据现场观测建立了转台系统故障特征模式库. 利用蚁群优化算法求解故障特征模式的最优分类问题, 并定义敏感度和明确度来评价蚁群搜索到的诊断规则的分类性能, 以减少故障特征信息中的冗余信息, 使诊断规则得到约简. 对某精密伺服转台的若干类故障诊断结果表明, 该方法具有收敛速度快、鲁棒性强、诊断精度高和结果可靠等优点.

**关键词** 精密伺服转台, 蚁群优化, 故障诊断, 数据挖掘, 分类算法  
**中图分类号** TP273

## Ant Colony Optimization for Fault Diagnosis of High Precision Servo Simulator

ZHEN Zi-Yang<sup>1</sup> WANG Dao-Bo<sup>1</sup> WANG Zhi-Sheng<sup>1</sup>

**Abstract** A new fault diagnosis method for high precision servo simulator is presented in this paper. Based on the field observation, a fault feature pattern base is built up. The ant colony optimization (ACO) is used for the optimal classification problem of the fault feature patterns, in which an index function based on the sensitivity and the specificity is defined to evaluate the performance of the diagnostic rule obtained by ACO, in order to decrease the redundant information of the fault features so that the diagnosis rules can be reduced. Diagnosis results of several types of faults of a real high precision servo simulator show that the diagnosis method based on ACO is characterized by fast convergence speed, strong robustness, high diagnosis accuracy, and reliable results.

**Key words** High precision servo simulator, ant colony optimization (ACO), fault diagnosis, data mining, classification algorithm

故障诊断技术的发展主要经历了人工诊断、现代诊断和智能诊断等三个阶段<sup>[1]</sup>. 发展至今, 故障诊断方法可划分为基于解析模型的方法、基于信号处理的方法和基于知识的方法等. 近年来, 基于人工智能的数据挖掘技术在复杂系统故障检测与诊断研究中得到广泛应用, 包括神经网络<sup>[2]</sup>、支持向量机<sup>[3]</sup>、粗糙集<sup>[4]</sup>、智能优化算法<sup>[5]</sup>以及相互之间的结合<sup>[6-8]</sup>等方法. 蚁群优化 (Ant colony optimization, ACO) 算法由 Dorigo 等通过模拟自然界蚂蚁集体出巢搜索最短觅食路径的行为而提出<sup>[9]</sup>, Parpinelli 等将 ACO 算法用于医学诊断应用中, 可获得比决策树分类算法 CN2 更高的分类准确率和更简便的分类规则<sup>[10]</sup>.

精密伺服转台是一种用于模拟飞行器姿态变化的高复杂、高精度和高可靠的机电设备, 是保障惯性导航系统地面仿真试验精度的关键设备. 为保证各个电子、机械、软件及其他部件长期安全可靠地运行, 提高故障诊断技术的研究具有非常重要的意义<sup>[11]</sup>. 针对转台系统的故障诊断问题, 文献 [12] 运用粗糙集理论直接从故障样本中导出诊断规则, 并对决策表进行约简处理; 接着, 文献 [13] 提出了粗糙集、ACO 算法和 BP 网络相结合的在线诊断方法.

本文的研究对象是课题组自主研制的某精密伺服转台, 首先建立故障特征模式库, 然后通过 ACO 算法寻优获得含较少条件项且较高诊断精度的故障诊断规则, 最后进行仿真研究.

## 1 精密伺服转台系统及其故障特征

### 1.1 伺服转台系统

精密伺服转台系统主要由指令系统、控制系统、执行器、反馈元件和被控对象组成, 其硬件组成框图如图 1 (见下页) 所示. 图 1 中, 指令系统构成人机交互界面, 可从信号发生器和开关按键输入指令, 通过 LED 数码显示器和发光二极管指示转台工作状态并监控转台. 控制系统由控制微机和控制器构成, 控制微机完成位置环的数字控制和数据处理等功能, 而控制器完成对转台工作状态的监控保护以及对电

收稿日期 2008-12-16 收修改稿日期 2009-03-11  
Received December 16, 2008; in revised form March 11, 2009  
国家自然科学基金 (60874037), 教育部博士点科研基金 (200702870-50), 江苏省普通高校研究生科研创新计划 (CX08B-091Z), 南京航空航天大学博士学位论文创新与创优基金 (BCXJ08-06) 资助  
Supported by National Natural Science Foundation of China (60874037), Specialized Research Fund for the Doctoral Program of Higher Education of China (20070287050), Graduate Student Research Innovation Program of Jiangsu Province (CX08B-091Z), and Innovation and Excellence Foundation of Doctoral Dissertation of Nanjing University of Aeronautics and Astronautics (BCXJ08-06)  
1. 南京航空航天大学自动化学院 南京 210016  
1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016  
DOI: 10.3724/SP.J.1004.2009.00780

流环和速度环的模拟控制和信号调理等工作, 控制器电路分为三大功能模块: 模拟控制电路模块、单片机控制电路模块和测角控制电路模块. 执行机构对控制信号进行功率放大并拖动电机转动. 反馈元件主要包括测速机、码盘、电位器等速度或位置传感器.

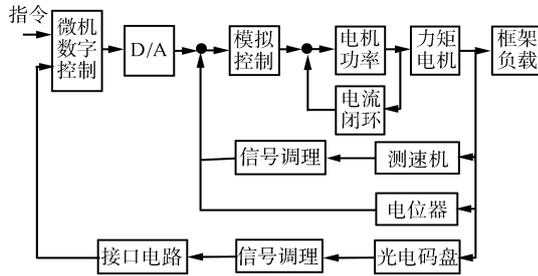


图1 伺服转台系统结构框图

Fig. 1 Structure diagram of servo simulator

### 1.2 故障特征模式库

精密伺服转台是一种用于惯性平台及惯性仪表研制、性能测试和鉴定的测试设备, 其故障类别大致分为执行器故障、传感器故障、控制器故障和机械台体故障等四个部分<sup>[11]</sup>. 执行器故障包括功率放大器故障和电机故障; 传感器故障包括测速机故障、码盘故障和电位器故障; 控制器故障分为软件故障、模拟电路故障和数字电路故障等.

针对某精密伺服转台的实际特性, 并根据具体特征表现得到属性值, 定义故障特征属性向量  $D = (d_1, d_2, \dots, d_{12})$ , 分别表示电机温度、功放温度、过流指示、串口显示、看门狗输出、过欠压指示、电位器回零、转台寻零、电机转动状态、位置反馈、速度反馈、功放输出等 12 个特征属性的取值, 取值与特征之间的关系可表示为:  $d_1$  和  $d_2$  取值: 1- 正常, 2- 过热;  $d_3$  取值: 1- 无, 2- 有;  $d_4$  取值: 1- 正常, 2- 不正常;  $d_5$  取值: 1- 高, 2- 低;  $d_6$  取值: 1- 无, 2- 过压, 3- 欠压;  $d_7$  取值: 1- 正常, 2- 不动, 3- 偏离;  $d_8$  取值: 1- 正常, 2- 不动, 3- 偏离或其他不正常;  $d_9$  取值: 1- 不影响, 2- 停止, 3- 减慢, 4- 加快, 5- 其他不正常;  $d_{10} \sim d_{12}$  取值: 1- 不影响, 2- 无, 3- 减小, 4- 增大, 5- 其他不正常.

根据现场调试经验, 建立转台系统的故障特征数据样本集, 如表 1 所示, 为限制篇幅, 表 1 仅给出了三类故障的样本数据,  $S = (s_1, s_2, \dots, s_{44})$  表示现场记录的 44 个故障模式样本, 其中  $s_1 \sim s_{10}$  为电机故障模式样本;  $s_{11} \sim s_{19}$  为功率放大器故障模式样本;  $s_{20} \sim s_{23}$  为测速机故障模式样本;  $s_{24} \sim s_{28}$  为码盘故障模式样本;  $s_{29} \sim s_{31}$  为电位器故障模式样本;  $s_{32} \sim s_{35}$  为软件故障模式样本;  $s_{36} \sim s_{38}$  为模拟电路故障模式样本;  $s_{39} \sim s_{44}$  为数字电路故障模式

样本.

从样本数据集可看出, 不同的特征数据往往对应同源故障, 并且特征属性较多, 都给故障诊断带来困难. 因此, 本文提出了基于 ACO 算法的智能分类算法, 试图找到含较少条件项、较高故障类别预测精度的诊断规则.

表 1 精密伺服转台的故障特征模式库

Table 1 Fault feature mode base of servo simulator

	$d_1$	$d_2$	$d_3$	$d_4$	$d_5$	$d_6$	$d_7$	$d_8$	$d_9$	$d_{10}$	$d_{11}$	$d_{12}$
$s_1$	2	1	2	1	1	2	2	2	2	2	2	4
$s_2$	1	1	2	1	1	2	2	2	2	2	2	4
$s_3$	1	1	1	1	1	1	1	1	3	3	3	4
$s_4$	2	1	1	1	1	1	1	1	4	4	4	3
$s_5$	1	1	1	1	1	1	1	1	3	3	3	4
$s_6$	2	1	1	1	1	1	1	1	4	4	4	3
$s_7$	1	1	1	1	1	1	3	3	5	5	5	5
$s_8$	1	1	2	1	1	2	2	2	2	2	2	4
$s_9$	2	1	1	1	1	1	2	2	2	2	2	4
$s_{10}$	1	1	2	1	1	2	2	2	2	2	2	4
$s_{11}$	1	1	1	1	1	3	1	1	2	2	2	4
$s_{12}$	1	2	1	1	1	2	1	1	4	4	4	3
$s_{13}$	1	2	2	1	1	2	1	1	1	1	1	1
$s_{14}$	2	2	2	1	1	1	1	1	4	4	4	3
$s_{15}$	1	1	1	1	1	1	1	1	5	5	5	5
$s_{16}$	1	2	2	1	1	1	2	2	2	2	2	2
$s_{17}$	1	2	2	1	1	2	3	3	5	4	4	5
$s_{18}$	1	2	2	1	1	2	3	3	5	4	4	4
$s_{19}$	1	1	1	1	1	1	3	3	5	5	5	5
$\vdots$												
$s_{39}$	1	1	1	1	1	1	1	3	4	2	1	4
$s_{40}$	1	1	1	1	1	1	1	3	5	5	5	5
$s_{41}$	1	1	1	2	1	1	1	1	1	1	1	1
$s_{42}$	1	1	1	2	1	1	2	2	2	1	5	5
$s_{43}$	1	1	1	2	1	1	1	1	5	5	5	5
$s_{44}$	1	1	1	1	1	1	1	1	5	5	5	5

## 2 蚁群优化算法

ACO 算法是一种启发式智能仿生优化算法, 具有正反馈、并行分布式计算等优点. 自然界蚁群觅食行为的基本思想是: 蚂蚁从蚁巢出发, 在所经过的路径上释放信息素, 则该路径上走过的蚂蚁越多, 留下的信息素也越多, 后来的蚂蚁更倾向于选择信息素较多的路径, 因此, 较优路径上的信息量会逐渐增大, 而较差路径上的信息素因为挥发而逐渐消减, 最终使整个蚁群找到通往食物源的最优路径.

第  $k$  只蚂蚁从节点  $i$  转移到下一节点  $j$  的状态转移概率可表示为

$$P_{ij}^k(t) = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{l=allowed} [\tau_{il}(t)]^\alpha [\eta_{il}(t)]^\beta} \quad (1)$$

其中,  $\tau_{ij}(t)$  表示该路径上存留的信息量;  $\eta_{ij}(t)$  反映蚂蚁从节点  $i$  转移到节点  $j$  的期望程度, 亦称能见度;  $\alpha, \beta$  分别表示信息素和能见度的启发性因子;  $t$  为蚁群批次, 表示算法迭代次数。

当蚁群完成一次搜索任务, 各路径上信息素可按如下规则进行调节

$$\tau_{ij}(t+1) = (1-\rho)\tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (2)$$

$$\Delta\tau_{ij}(t) = \sum_{k=1}^N \Delta\tau_{ij}^k(t) \quad (3)$$

式中, 若第  $k$  只蚂蚁经过该段路径, 则  $\Delta\tau_{ij}^k(t) = Q/L^k(t)$ , 否则  $\Delta\tau_{ij}^k(t) = 0$ ,  $Q$  表示信息素强度,  $L^k(t)$  为蚂蚁在本次搜索中所走路径的总长度;  $\rho$  为信息素挥发系数,  $\rho \in [0, 1]$ ;  $N$  为当前批次出巢的蚂蚁只数。

### 3 基于蚁群优化算法的故障诊断方案设计

#### 3.1 方案设计的关键问题分析

转台发生故障的特征信息之间存在一定的冗余性, 可能只需少量的特征信号就可以预测出故障源。用于诊断转台故障原因的蚁群分类算法模拟蚁群搜索最优路径来优化诊断规则。

总的来说, 诊断方案的设计需要解决如下几个关键问题:

##### 1) 蚁群路径和节点的生成

基于 ACO 算法原理, 定义第 1 个节点为蚁巢 (表示故障源), 其他 12 个节点表示属性, 路径表示属性的特征值, 特征值取 0 表示诊断规则不考虑该属性, 其他取值的含义与故障特征向量  $D$  中元素的取值含义相同。蚂蚁走到最后一个节点表示找到食物源, 路径组成的向量代表一条诊断规则, 由此得到模拟蚁群搜索路径的故障诊断图如图 2 所示。

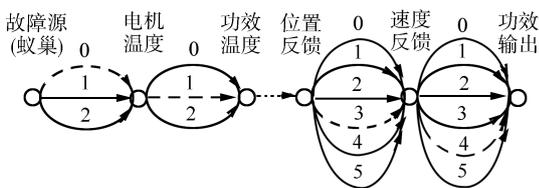


图 2 模拟蚁群搜索路径的故障诊断图

Fig. 2 Fault diagnosis graph simulating routes of ACO

例如, 图 2 中虚线表示在某故障预测中蚂蚁的行走路径, 则路径序列  $R = (0, 1, \dots, 3, 4)$  对应的一条规则可表示为:

IF (功放温度正常) AND ( $\dots$ ) AND (速度反馈减小) AND (功放输出增大) THEN (属于该类故障)

##### 2) 分类性能评价函数的建立

蚂蚁走过的路径所生成的诊断规则的性能由分类精度来定量评价, 表示为

$$f(t) = \frac{n_{TP}(t)}{n_{TP}(t) + n_{FN}(t)} \cdot \frac{n_{TN}(t)}{n_{FP}(t) + n_{TN}(t)} \quad (4)$$

式中,  $t$  为算法迭代次数,  $n_{TP}$  表示属于该类故障的样本数据被预测成属于该类的样本个数;  $n_{TN}$  表示不属于该类的样本数据被预测成不属于该类的样本个数;  $n_{FP}$  表示属于该类的样本数据被预测成不属于该类的样本个数;  $n_{FN}$  表示不属于该类的样本数据被预测成属于该类的样本个数; 称  $n_{TP}/(n_{TP} + n_{FN})$  为敏感度, 表示属于该类的样本数据被预测成属于该类的比例; 称  $n_{TN}/(n_{FP} + n_{TN})$  为明确度, 表示不属于该类的样本数据被预测成不属于该类的比例<sup>[10]</sup>。可以看出,  $f \in [0, 1]$ , 且  $f$  越接近于 1, 则该诊断规则对该类的判断越准确。

##### 3) 路径能见度的确定

第  $i$  个属性  $A_i$  的第  $j$  个特征值  $V_{ij}$  所代表的路径上的能见度可由该属性特征值的信息熵量度<sup>[10]</sup>, 即表示为

$$\eta_{ij} = \frac{\log_2 K - H(W|A_i = V_{ij})}{\sum_{i=1}^a \sum_{j=1}^{b_i} \log_2 K - H(W|A_i = V_{ij})} \quad (5)$$

式中,  $H(\cdot)$  表示属性特征值的熵值,  $K$  表示类数,  $W$  表示类属性,  $a$  为表征故障的属性个数,  $b_i$  是第  $i$  个属性的特征值个数。信息熵表示为

$$H(W|A_i = V_{ij}) = - \sum_{w=1}^K \{P(w|A_i = V_{ij}) \log_2 P(w|A_i = V_{ij})\} \quad (6)$$

式中,  $P(w|A_i = V_{ij})$  表示  $A_i = V_{ij}$  数据属于第  $w$  类的经验概率,  $i = 1 \sim a, j = 1 \sim b_i$ 。

从式 (5) 和 (6) 看出, 若路径上特征值的熵值越大, 表示该属性特征值在各类中分布越均匀, 则通过它来确定故障类别的难度越大, 所以该节点的能见度越低。在同等分类性能条件下, 诊断规则中包含的属性或条件项越少, 则该规则的泛化能力越强, 这正是搜索最佳诊断规则时所期待出现的, 因此特征值取 0 的路径的能见度最高。

## 4) 路径信息素的初始设置与更新

路径上的初始信息素是平均分配的, 其计算公式为

$$\tau_{ij}(t=0) = \frac{1}{a} \sum_{i=1}^a b_i \quad (7)$$

式中,  $i = 1 \sim a, j = 1 \sim b_i$ .

蚂蚁走完一条路径再更新路径上的信息素, 其更新公式为

$$\tau_{ij}(t+1) = \tau_{ij}(t) + \tau_{ij}(t)f(t) \quad (8)$$

式中,  $f$  为对应诊断规则对样本数据进行分类的性能评价,  $f$  越高, 则蚂蚁在经过的路径上释放的信息素越多. 需要注意的是, 信息素更新后, 再作归一化处理, 使所有路径上的信息素之和为 1, 同时也能减小未被选择路径上的信息素, 相当于信息素的挥发过程.

## 5) 状态转移概率的计算

蚂蚁从第  $i$  个属性中第  $j$  个特征值所代表的路径上经过的转移概率表示为

$$p_{ij}(t) = \frac{\eta_{ij}\tau_{ij}(t)}{\sum_{l=1}^{b_i} \eta_{il}\tau_{il}(t)} \quad (9)$$

式中,  $i = 1 \sim a, j = 1 \sim b_i$ .  $\tau_{ij}$  值越大表示先前经过该路径的蚂蚁越多, 说明包含该条件项的诊断规则的分类性能越好.  $\tau_{ij}$  和  $\eta_{ij}$  越大, 则  $p_{ij}$  越大, 表示蚂蚁更倾向于选择从该路径段经过.

## 3.2 方案的具体实施步骤

在解决其他优化问题中, 往往是蚂蚁先走完所有节点后再进行性能评价, 但是在故障诊断中, 这样会因为条件项过多而使得性能评价近乎为零, 从而导致算法失效. 为避免上述问题, 算法每次只派出一只蚂蚁, 蚂蚁每经过一段路径则对应的诊断规则考虑添加一个条件项. 若能提高分类性能, 则该条件项被选中; 否则被放弃, 此时相当于该段路径的特征值取为 0.

基于上述设计方案, 蚁群分类算法的主要实现步骤描述如下:

**步骤 1.** 初始参数设置: 根据式 (5) 和 (6) 计算各路径段的能见度; 根据式 (7) 初始化路径上的信息素分布; 从蚁巢派出第 1 只蚂蚁, 随机生成一条初始路径.

**步骤 2.** 置算法迭代次数  $t = 1$ .

**步骤 3.** 蚂蚁经过第  $i$  段路径 (即第  $i$  个属性), 对应规则添加一个条件项, 并将该规则用于样本数

据分类, 计算当前分类精度  $f_i(t)$ . 若满足  $f_i(t) \leq f_{i-1}(t)$  则规则中取消该条件项, 即蚂蚁选择走特征值为 0 的路径段, 继续移动; 否则更新分类精度. 当蚂蚁走完一条路径, 得到最终分类精度为  $f_a(t)$ . 需要注意的是,  $f_0(t)$  为给定初始评价.

**步骤 4.** 根据  $f_a(t)$ , 利用式 (8) 修改所经过路径的信息量, 并结合能见度信息, 根据式 (9) 计算所有路径的状态转移概率  $p_{ij}(t)$ , 再根据  $p_{ij}(t)$  生成下一只蚂蚁要走的路径,  $i = 1 \sim a, j = 1 \sim b_i$ .

**步骤 5.** 若满足  $f_a(t) \geq \varepsilon_0$ ,  $\varepsilon_0$  为给定分类精度, 则继续执行步骤 6, 否则执行步骤 7.

**步骤 6.** 记录该蚂蚁搜索到的诊断规则, 对剩余特征模式库中的样本数据进行分类, 消去被该规则正确预测的该类样本数据; 重新初始化所有路径的信息素和能见度, 并随机生成一条下一只蚂蚁准备走的路径.

**步骤 7.** 若该类样本数据被正确预测的样本个数达到预定要求, 或算法满足最大迭代次数  $t_{\max}$ , 则算法迭代过程结束, 并记录最终数据; 否则,  $t = t+1$ , 返回步骤 3, 继续派出蚂蚁搜索下一条诊断规则.

## 4 仿真研究

针对表 1 所示的某精密伺服转台的故障样本数据集, 以对电机、功放、数字电路的故障诊断为例, 采用 ACO 算法来搜索能够较准确预测该类故障的优化规则, 进行仿真研究.

仿真参数设置为: 初始评价  $f_0(t) = 0$ ; 给定分类精度  $\varepsilon_0 = 0.8$ ; 给定 ACO 算法最大迭代次数  $t_{\max} = 100$ , 这里表示派出蚂蚁最大批次或最多只数; 预测电机故障时, 10 个样本数据中要求至少被正确预测 8 个; 预测功放故障时, 9 个样本数据中要求至少被正确预测 7 个; 预测数字电路故障时, 6 个样本数据中要求至少被正确预测 4 个.

经过数次试验, 得到仿真结果如表 2 所示. 其中,  $n_{TP}$  为属于该类故障的样本数据被预测成属于

表 2 蚁群优化算法的故障诊断结果

Table 2 Fault diagnosis results based on ACO algorithm

故障类别	规则数目	迭代次数	诊断规则	$f_a(t)$	$n_{TP}$
电机	3	6	IF $k_1 = 2$ and $k_2 = 1$	0.8500	4
			IF $k_1 = 1$ and $k_6 = 2$ and $k_9 = 2$	0.9189	3
			IF $k_9 = 3$ and $k_{11} = 3$	0.9714	2
功放	3	11	IF $k_1 = 1$ and $k_2 = 2$	0.8974	5
			IF $k_1 = 2$ and $k_2 = 2$	0.9211	1
			IF $k_5 = 1$ and $k_6 = 3$	0.9459	1
数字电路	2	7	IF $k_4 = 2$	0.9268	3
			IF $k_6 = 1$ and $k_7 = 1$ and $k_{10} = 2$	0.9500	1

该类的样本个数,  $f_a(t)$  为实际分类精度。

从仿真结果可知: ACO 算法只需很少的迭代次数就能搜索到具有含较少条件项、较高分类精度的诊断规则, 并且能够正确预测出预定的该类故障样本, 其中针对电机、功放、数字电路故障诊断问题, 蚂蚁分别搜索出 3、3、2 条具有高分类精度的规则。

基于该诊断方案, 对其他故障类别的诊断规则的寻优实验结果同样验证了该方案的有效性和稳定性。当然, 为提高故障诊断精度和可靠度, 需要适当增加故障模式库中的样本数目。

## 5 结论

本文在建立精密伺服转台故障模式库的基础上, 利用 ACO 算法对转台故障诊断规则进行了优化处理, 消除了故障属性表征内在的冗余属性, 以达到利用较少的条件项就能较准确地判断故障类别的目的。对某精密伺服转台的故障诊断实验表明了 ACO 算法具有快速搜索能力, 蚁群寻优后的故障诊断规则具有规则数和条件项少、诊断精度高、预测成功率高等优点。因此, 基于 ACO 算法的数据挖掘技术在故障诊断领域中具有广阔的应用前景。

## References

- 1 Frank P M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy – a survey and some new results. *Automatica*, 1990, **26**(3): 459–474
- 2 Saxena A, Saad A. Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems. *Applied Soft Computing*, 2007, **7**(1): 441–454
- 3 Liang J, Du R. Model-based fault detection and diagnosis of HVAC systems using support vector machine method. *International Journal of Refrigeration*, 2007, **30**(6): 1104–1114
- 4 Zhao C H, Zhao X Z, Gao H L, Wu G. Knowledge mining for fault diagnosis based on rough sets theory. In: Proceedings of the International Conference on Fuzzy Systems. Hong Kong, China: IEEE, 2008. 744–749
- 5 Wang L, Niu Q, Fei M R. A novel quantum ant colony optimization algorithm and its application to fault diagnosis. *Transactions of the Institute of Measurement and Control*, 2008, **30**(3-4): 313–329
- 6 Zheng Xiao-Xia, Qian Feng. Fault diagnosis based on rough sets decision tree model and ant colony algorithm. *Systems Engineering – Theory and Practice*, 2007, **27**(3): 140–144 (郑小霞, 钱锋. 基于粗糙决策模型和蚁群算法的故障诊断. 系统工程理论与实践, 2007, **27**(3): 140–144)
- 7 Dong L X, Xiao D M, Liang Y S, Liu Y L. Rough set and fuzzy wavelet neural network integrated with least square weighted fusion algorithm based fault diagnosis research for power transformers. *Electric Power Systems Research*, 2008, **78**(1): 129–136
- 8 Lin L, Wang H J, Dai C L. Fault diagnosis for wireless sensor network's node based on Hamming neural network and rough set. In: Proceedings of the IEEE Conference on Robotics, Automation, and Mechatronics. Chengdu, China: IEEE, 2008. 566–570

- 9 Dorigo M, Maniezzo V, Colorni A. Ant system: optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 1996, **26**(1): 29–41
- 10 Parpinelli R S, Lopes H S, Freitas A A. Data mining with an ant colony optimization algorithm. *IEEE Transactions on Evolutionary Computation*, 2002, **6**(4): 321–332
- 11 Lu Wen. Research and Realization of Advanced Fault Diagnosis Technology in the System of High Precision Servo Turntable [Master dissertation], Nanjing University of Aeronautics and Astronautics, China, 2005 (陆雯. 精密伺服转台系统先进故障诊断技术研究是实现 [硕士学位论文], 南京航空航天大学, 中国, 2005)
- 12 Duan Hai-Bin, Wang Dao-Bo, Huang Xiang-Hua, Han Shuo-Tiao. Research on fault diagnosis of high precision servo simulator based on rough set theory. *China Mechanical Engineering*, 2004, **15**(21): 1895–1898 (段海滨, 王道波, 黄向华, 韩朔眺. 基于粗集理论的高精度伺服仿真转台故障诊断研究. 中国机械工程学报, 2004, **15**(21): 1895–1898)
- 13 Duan H B, Yu X F, Ma G J. Novel hybrid approach for fault diagnosis in 3-DOF flight simulator based on BP neural network and ant colony algorithm. In: Proceedings of the IEEE Swarm Intelligence Symposium. Honolulu, USA: IEEE, 2007. 371–374



**甄子洋** 南京航空航天大学自动化学院博士研究生。主要研究方向为信息融合控制、无人机飞行控制和计算智能。本文通信作者。

E-mail: zhenziyang@nuaa.edu.cn

(**ZHEN Zi-Yang** Ph. D. candidate at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. His research interest covers information fusion control, unmanned aerial vehicle (UAV) flight control, and computational intelligence. Corresponding author of this paper.)



**王道波** 南京航空航天大学自动化学院教授。主要研究方向为无人机飞行控制和航空仿真。

E-mail: dbwangpe@nuaa.edu.cn

(**WANG Dao-Bo** Professor at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. His research interest covers UAV flight control and aeronautical simulation.)



**王志胜** 南京航空航天大学自动化学院副教授。主要研究方向为无人机飞行控制和信息融合。

E-mail: wangzhisheng@nuaa.edu.cn

(**WANG Zhi-Sheng** Associate professor at the College of Automation Engineering, Nanjing University of Aeronautics and Astronautics. His research interest covers UAV flight control and information fusion.)