基于 PCA 和粗糙集构建决策树的变电站故障诊断

张延松，赵英凯

（南京工业大学自动化与电气工程学院，江苏 南京 210009）

摘要：提出一种基于主元分析（PCA）和粗糙集理论结合继而构建决策树的故障诊断方法。该方法利用 PCA 对原始故障决策表的条件属性集进行降维处理，得到由主元变量构成的故障决策表，采用等频分割方法对这一决策表的数据离散化，进而采用基于主元属性重要度的粗糙集属性约简算法得到离散后的决策表的最小约简，以约简数据集为样本基于核属性采用一种改进的决策树算法训练学习，构建故障决策树进行诊断决策。测试实例证明了该方法能简化故障诊断系统，提取容错性较强的诊断规则，提高了故障的识别率。

关键词：主元分析；粗糙集；决策树；变电站；故障诊断

Fault diagnosis of substation by the constructed decision tree based on principal component analysis(PCA) and rough set

ZHANG Yan-song，ZHAO Ying-kai
(Automation and Electrical Engineering College，Nanjing University of Technology，Nanjing 210009，China)

Abstract: A method for substation fault diagnosis based on principal component analysis(PCA) and rough set theory，then to constructed decision tree, is proposed. By this method，PCA is used to decrease the dimension of all the condition attributes of the original fault decision table and get fault decision table that consists of principle component variables. Then，an equal-frequency devision method is used to discrete the value of the above decision table. The next is that a rough attribute reduction based on the significance of principle component variables is applied to obtain a minimum reduction of the discrete decision table. Finally，based on the core attributes, an improved decision tree algorithm is used to train the reducted data set and construct a decision tree for the diagnosis. Test proved that this method can simplify the fault diagnosis system, extract the diagnosis rules of better fault tolerance and increase the fault recognition rate.

Key words: PCA；rough set；decision tree；substation；fault diagnosis

中图分类号： TM711 文献标识码：A 文章编号： 1674-3415(2010)14-0104-06

0 引言

变电站是电力输配电系统中非常重要的一环，涉及到许多安全运行、可靠供电方面的问题。变电站故障诊断就是从变电站的某些检测量中得到故障征兆信息，再通过对这些故障征兆信息的分析与处理，判断出故障源的位置。其中检测量由厂站监控系统和故障录波器提供，故障征兆包括保护开关动作、断路器跳闸等，而需判断的故障源通常有母线、变压器、无功补偿设备等[1]。

多元统计理论中的主元分析法可以提取样本集的主元，降低样本的维数，甚至可以实现样本的最优压缩[2]。粗糙集理论[3]是由 z．Pawlak 于 1982 年提出的一种处理不精确和不确定知识的数学工具，其主要思想就是在保持分类能力不变的前提下，通过知识约简，将决策系统简化，提高系统潜在知识的清晰度。决策树算法是分类发现算法中最常见的一种方法[4]，在故障诊断的决策信息规则提取中有着广泛的应用。

主元分析能将高维的故障样本空间投影到相对独立的低维空间，以降低分析难度，但不适合解决非线性[5-6]、时变动态[7]、故障隔离[8]等问题，单独使用时需要对其进行改进。粗糙集理论被用于电力系统故障诊断时，使用不同的属性约简[9-11]和值约简方法可能会得到不尽一致的故障诊断规则，势必对故障诊断结果的正确性造成影响；目前属性约简方法很多，但值约简方法研究较少[12-14]，这些也给约简方法的选取和使用带来困难，所以仅依靠粗糙集理论的故障诊断方法优势不是很明显。决策树具有对无次序的实例进行快速分类并记忆的能力，其产生的规则是树状结构，规则间关系清晰，使得推理的结果便于解释，但难点在于分支节点的选择

上，选择的好坏关系到计算的复杂度和决策规则的质量，文献[15-16]分别以信息熵降大小和信息增益比高低为依据确定分支节点，但存在计算复杂、效率不高的问题。本文吸收了 PCA 在特征提取和数据降维的优点，以及粗糙集理论能进行知识约简的优势，在尽可能少丢失信息的前提下浓缩故障样本，构造出易操作、复杂度小、直观性强的决策树进行故障诊断。

1　基于PCA的故障特征提取

根据PCA原理，基于PCA从故障决策表中提取故障信号特征的算法（算法1）如下：

（1）设故障信号的采样点为r个，也就是决策表的条件属性个数为r个，将其排列成一维行向量，可以表示成：$x=(a_1,a_2,\cdots,a_r)$。故障信号样本总数为 N，每个故障样本均为 r 维，分别对应行向量 $x_1,x_2,\cdots,x_N$，构成N行r列的故障数据矩阵$\boldsymbol{X}$。

（2）计算全体故障样本的平均值向量

$$m=\frac{1}{N}\sum_{i=1}^{N}x_i$$

（3）计算协方差矩阵

$$\boldsymbol{C}_x=\frac{1}{N}\sum_{i=1}^{N}(x_i-m)^{\mathrm{T}}(x_i-m)$$

（4）求协方差矩阵 $\boldsymbol{C}_x$ 的特征值 λ_i 及相应的正交归一化特征向量 u_i，其中 $i=1, 2, \cdots, r$；

（5）将特征值按由大到小顺序排列，并按照下式计算前 p 个主元的累积贡献率：

$$\eta(p)=\sum_{i=1}^{p}\lambda_i \Big/ \sum_{i=1}^{r}\lambda_i,\ p<r$$

累积贡献率用于衡量新生成分量对原始数据的信息保存程度，通常要求其大于 85%即可；

（6）取前 p 个较大特征值对应的特征向量构成变换矩阵 $\boldsymbol{T}$：$\boldsymbol{T}=(u_1,u_2,\cdots,u_p)$，$p<r$；

（7）通过 $Y=X\boldsymbol{T}$ 计算前 p 个主成分，达到降低维数的目的，将每种故障信号样本的矢量向步骤（6）中的特征矢量 $\boldsymbol{T}$ 张成的子空间投影，就可提取故障信号的 p 维特征矢量。

2　基于粗糙集的故障决策表约简

主元分析方法将原始故障样本决策表浓缩成由主元变量Y构成的新故障样本表，表中的数据信息是经过投影后的连续型数据，在用粗糙集理论解决连续系统的问题时，要求信息表必须是离散值，所以必须通过离散化方法，将连续型数据转化成离散化数据。离散化方法很多，本文采用等频率离散化方法。设主元变量故障决策表为：$DT=(U,A=C\cup D,V,f)$，其中：U为样本集序号，C为条件属性集，$C=Y=\{y_1,y_2,\cdots,y_p\}$，$D$为决策属性集，$V=\{a_1,a_2,\cdots,a_p\}$为条件属性值集合，$f$为相应的决策属性值。等频法思想如下[17]：

在 y_i 上有N个离散值，给定一个参数k，把这N个离散值分成k+1段，每段有$N/(k+1)$个离散值，则断点 c_j^i 的确定方法如下：对于条件属性 y_i，以值升序集合表示它的值域，即：

$$\begin{cases} y_i(U)=\{y_1^i,\cdots,y_m^i,y_{m+1}^i,\cdots,y_N^i\} \text{ 设断点 } c_j^i \text{ 落入值} \\ y_1^i=c_0^i,\cdots,y_N^i=c_{k+1}^i, i=1,\cdots,p \end{cases}$$

y_m^i, y_{m+1}^i 之间，则断点 $c_j^i=\frac{(y_m^i+y_{m+1}^i)}{2}$，这样可求出 c_j^i 中的k个断点（$c_1^i,c_2^i,\ldots,c_k^i$）。于是 y_i 就被划分为k+1个区间，而每个区间可以用一个离散值来代替即完成了离散化过程，得到了离散化的故障决策表。然后从粗糙集的相对正域出发，采用基于属性重要度的属性约简算法约简离散的故障决策表[18]。该算法（算法2）如下：

输入：决策表 $DT=(U,A=C\cup D,V,f)$

输出：DT 的一个相对约简B

（1）令C相对于D的核 $CORE_C(D)=\varnothing$；

（2）$\forall c_i\in C$，如果 $POS_{C-ci}(D)\neq POS_C(D)$，则令 $CORE_C(D)=CORE_C(D)\cup\{c_i\}$，直到遍历条件属性全集中的每一个属性；

（3）设 DT 的一个相对约简为 B，令 $B=CORE_C(D)$；

（4）如果 $POS_B(D)=POS_C(D)$，则 DT 的一个约简为 $B=CORE_C(D)\in RED_C(D)$，属性约简完成转到第(6)步，否则转到第(5)步；

（5）$\forall c_i\in C\setminus B$，计算属性重要度 $sig(c_i,B;D)=\left|POS_{B\cup\{ci\}}(D)\right|-\left|POS_B(D)\right|$，求得 $c_m=\arg\max_{Ci\in C\setminus B} sig(c_i,B;D)$，这里的 arg 表示取使重要度达到最大的属性 c_i，而非最大的重要度值（若同时存在多个属性满足最大值，则从中选取一个与B的属性值组合数最少的属性作为 c_m），令 $B=B\cup\{c_i\}$，转到第(4)步；

（6）输出B，算法结束。

至此，在不影响分类的前提下我们得到了复杂

度小、最简单的故障样本决策表。

3 故障决策树的构建以及故障的诊断

决策树[19-20]可视为一颗分类模型树，树的根节点是整个数据集合空间，每个分节点是一个分裂问题，它是对属性的测试，该测试属性将数据集分割成两个或更多块，分节点继续分裂生长直至叶节点产生，每个叶节点是带有某个分类的数据分割。从决策树的根节点到叶节点的一条路径就形成了一条分类规则。决策树的核心问题是测试属性选择与决策树修剪。

经过算法2的处理，我们得到约简后的决策表、决策表的核属性和最小约简集。核属性是样本数据集的最重要的分类属性，去除核属性后将会对决策表的分类能力造成很大的误判。基于此，为了得到高效、简单的分类规则，我们选取核属性作为故障决策树的根节点测试属性；依据核属性的不同属性值组合建立决策树的分支；分支节点必为最小约简中的非核属性，我们每次都选择候选分支属性集中的具有最大属性重要度的属性作为分支节点，这一属性也是其对应的属性值类别最多的那一属性。采用递归的方法, 重复建立树的下层节点和分支过程直到剩余属性值集合包含同一类别的数据为止，如此确保了找到一棵简单的分类决策树。但许多分类规则都存在一个普遍的过度拟合问题, 有必要对生成的初始决策树进行简化修正, 也称为剪枝, 剪枝后得到的新的决策树可能会使得它对训练集分类的误判率增大, 但同时却能减少对新的数据集分类的误判率。剪枝完成后就得到了容错性好、适应性强的决策树，即可得到分类规则进行诊断。

4 变电站故障诊断实例分析

图1是某工厂变电站一次系统图的一个部分，采用单母线分段连接，该变电所各段均配有电流速断保护（Current Instantaneous Trip Protection，TP）和过流保护（Overcurrent Protection，OP）。图1中只标出了TP保护，R1、R2、R4、R5代表四个故障区域，CB1~CB5为断路器，各线路均有两种保护和相应的断路器。

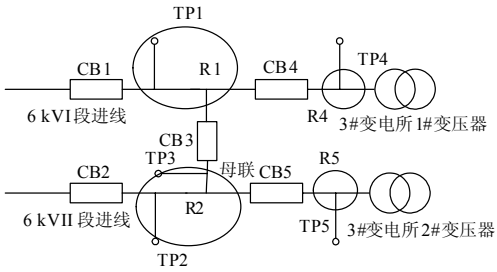

图1 一个简单的变电站系统图

Fig.1 Graph of a simple substation system

表 1 是由图 1 的故障样本构成的决策表，共计 13 个样本，U 代表论域（样本编号），其条件属性为断路器 CB1~CB5，电流速断保护 TP1~TP5，过流保护 OP1~OP5，条件属性取值为“0”或“1”，其中“1”表示断路器由闭合变位为断开或保护动作，“0”表示断路器未变位或保护未动作。决策属性为故障区域 FA（Fault Area），分别为 R1、R2、R4、R5 和 No(表示无故障)。

表1 故障样本决策表

Tab.1 Decision table of fault samples

U	CB1	TP1	OP1	CB2	TP2	OP2	CB3	TP3	OP3	CB4	TP4	OP4	CB5	TP5	OP5	FA
1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	R1
2	1	0	1	0	0	0	0	0	0	0	0	0	0	0	0	R1
3	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	R2
4	0	0	0	1	0	1	0	0	0	0	0	0	0	0	0	R2
5	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	R1
6	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	R2
7	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	R1
8	0	0	0	0	0	0	1	0	1	0	0	0	0	0	0	R2
9	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	R4
10	0	0	0	0	0	0	0	0	0	1	0	1	0	0	0	R4
11	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0	R5
12	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	R5
13	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	NO

4.1 故障决策表的主元特征提取

首先，使用本文中的算法 1 对表 1 进行主元分析，提取出故障样本的主元变量，得到主元 Y1, Y2, Y3, Y4, Y5, Y6, Y7, Y8, Y9, Y10。前 9 个主元的贡献率如图 2 所示。根据图 2 贡献率的数值，取累计方差贡献率 η_k≥85%的主元。前 8 个主元 Y1~Y8 的累积贡献率为 91.56%，大于给定的 85%的取值，用这 8 个主元对样本进行分析不会损失太多的信息。$\boldsymbol{X}$ 为表 1 中各条件属性对应的数据矩阵，维数为 13×15。$\boldsymbol{T}$ 为前 8 个主元表达式对应的系数矩阵, 其维数为 15×8。令 Y=[Y1, Y2, Y3, Y4, Y5, Y6, Y7, Y8]，根据算法 1 可知 $\boldsymbol{Y}=\boldsymbol{XT}$，得到主元变量故障决策表的数据矩阵，由此建立由主元作为条件属性的故障样本表。

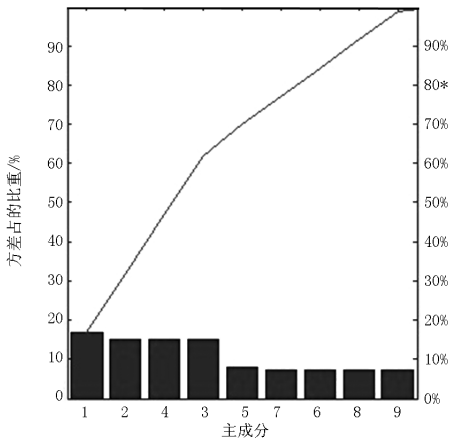

图2 主元贡献率

Fig.2 Percentage of principal components

4.2 基于粗糙集的主元故障决策表的离散化及其约简

设参数k=3，使用本文中的等频率离散化方法对主元样本表数据进行离散化，每个主元下均可得到3个数据大小范围不同的离散区间，区间由小到大分别以离散数0、1、2代替，然后删除有重复的离散化的样本，离散化结果如表2所示。

在不影响分类决策的前提下，为了约简冗余的主元变量，我们使用本文中的算法2对表2进行主元条件属性的约简，进一步浓缩样本空间。经过运算，得到表2的核条件属性core=[Y4, Y5], 一个最小属性约简redu=[Y2, Y3, Y4, Y5]。以redu为条件属性，决策属性不变，从表2构建约简故障样本，并将重复样本删除，我们就可以得到粗糙集约简后的故障决策表，如表3所示。

表2 离散化决策表

Tab.2 Discreted decision table

U	Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y8	FA
1	0	1	0	1	1	0	1	1	R1
2	0	1	0	1	1	2	1	1	R1
3	0	0	2	0	1	1	0	2	R2
4	0	0	2	0	1	1	2	0	R2
5	2	1	1	1	2	1	1	1	R1
6	2	1	1	1	2	1	1	1	R2
7	2	1	1	1	0	1	1	1	R1
8	2	1	1	1	0	1	1	1	R2
9	0	2	2	2	1	1	0	0	R4
10	0	2	2	2	1	1	2	2	R4
11	0	0	2	2	1	1	2	0	R5
12	0	0	2	2	1	1	0	2	R5
13	2	1	1	1	1	1	1	1	NO

表3 约简后的决策表

Tab.3 Reducted decision table

U	Y2	Y3	Y4	Y5	FA
1	1	0	1	1	R1
2	0	2	0	1	R2
3	1	1	1	2	R1/R2
4	1	1	1	0	R1/R2
5	2	2	2	1	R4
6	0	2	2	1	R5
7	1	1	1	1	NO

4.3 决策树的生成

由表3知，约简后的故障决策表的核条件属性core=[Y4,Y5]， redu=[Y2, Y3, Y4, Y5]为故障决策表的一个约简。根据上述决策树构建方法，选择core为根节点测试属性，该节点有5种数据组合，产生了5个分支，其中(0, 1)、(1, 2)、(1, 0)组合只能产生叶节点，不再分裂，即可形成规则。(1, 1)组合的下层候选节点为[Y2, Y3]，根据表3可知Y3的属性值的类别多于Y2，形成决策的重要度大于Y2，选择Y3作为该组合下的下层分支节点。其他节点据此递推，最终得到的故障分类决策树如图3所示。

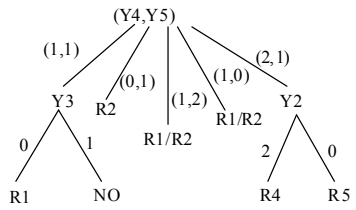

图3 故障决策树

Fig.3 Decision tree of faults

4.4 故障诊断测试与结果分析

我们从变电站监控系统中取得图1所对应的5条实际故障数据如表4所示，表中每个记录均包括了某些保护开关拒动或误动的故障数据，即为故障测试样本S。我们根据上文思路，首先利用算法1得到S的主元变量数据矩阵$\boldsymbol{D}$=S*T，从而建立实际故障样本的主元决策表，然后依照上述的离散化准则对其进行离散化，我们得到离散后的主元故障决策表如表5所示。

表4 测试样本

Tab.4 Test sample

U	CB1	TP1	OP1	CB2	TP2	OP2	CB3	TP3	OP3	CB4	TP4	OP4	CB5	TP5	OP5
1	1	0	0	0	1	0	0	0	0	0	0	0	0	0	0
2	1	1	0	0	0	1	0	0	0	0	0	0	0	0	0
3	0	1	0	1	1	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	1	0	1	0	0	0	0	0
5	0	0	1	0	0	1	0	0	1	0	0	0	1	0	1

表5 表4的离散化

Tab.5 Discretazition of Tab.4

U	Y1	Y2	Y3	Y4	Y5	Y6	Y7	Y8
1	0	1	0	1	1	1	0	2
2	0	1	0	1	1	0	2	0
3	0	0	1	0	1	0	0	2
4	2	2	2	2	1	1	1	1
5	0	0	1	1	2	1	0	0

图3的决策树有7个分支，相应地我们可得到7条诊断规则。我们可以根据决策树的各个节点的取值选择决策树的一条支路得到相应的故障区域。按照图3结合表5进行故障诊断，逐行比照，得到相应的故障分别为：FA={R1, R1, R2, R4, R5}，而这与实际的故障是一致的。该方法对这5个测试样本故障识别率达100%。

综上所述，构建的决策树不仅能大部分反映故障的信号特征，而且诊断规则简单、易懂、直观，诊断起来速度更快。经过PCA和粗糙集的处理，故障样本的浓缩率为53.85%，大大减少了数据样本，计算量小；特征约简率为26.67%，能使最主要的信号特征凸显出来，使工程人员在生产过程中更容易发现故障并及时诊断。诊断实例证明了该方法是行之有效的。

5 结论

本文在研究 PCA 特征提取、粗糙集属性约简的基础上，结合变电站的故障诊断特点，提出了一种改进的决策树构建方法，并用于变电站的故障诊断，是个有益的尝试和探索。使用主元分析处理故障样本，使得原本规模大、数据变量多的数据信息维数大大降低，同时也降低了决策诊断信息系统的分析难度；采用基于粗糙集核属性和属性重要度的方法构建的决策树简单、直观、规则易于提取，而且复杂度小，具有很好的容错性和识别效果。这一故障诊断方法还可以推广到其他对象，能被用于解决其他领域的故障诊断、模式识别等问题上。

参考文献

[1] 刘青,等. 基于多知识库与粗糙集理论的变电站故障诊断方法[J]. 华东电力，2006，34(12)：27-28.
LIU Qing, et al. Substation fault diagnosis based on multi-knowledge base and rough set theory[J]. East China Electric Power, 2006，34(12)：27-28.

[2] Johnson R A，Wichern D W. 实用多元统计分析[M]. 陆璇,译. 北京：清华大学出版社，2001.
Johnson R A, Wichern D W. Applied multivariate statistical analysis[M]. LU Xuan, trans. Beijing: Tsinghua University Press, 2001.

[3] Pawlak Z. Rough sets[J]. International Journal of Computer and Information Science, 1982, 11：341-356.

[4] Quinlan J R. Induction of decision trees[J]. Machine Learning, 1986 (1)：81-106.

[5] David Antory, Uwe Kruger, Irwin G W, et al. Industrial process monitoring using nonlinear principal component models[C].//Second IEEE International Conference on Intelligent Systems. Kine：2004: 293-298.

[6] Choi Sang Wook, Lee Changkyu, Lee Jong-Min, et al. Fault detection and identification of nonlinear processes based on kernel PCA[J]. Chemometrics and Intelligent Laboratory Systems, 2005, 75(1)：55-67.

[7] Choi Sang Wook, Lee In- Beum. Nonlinear dynamic process monitoring based on dynamic kernel PCA[J]. Chemical Engineering Science, 2004,59(24)：5897-5908.

[8] Thaddeus T Shannon, David Abercrombie, et al. Improved

process monitoring with independent components[C]. //IEEE/SEMI Advanced Semiconductor Manufacturing Conference. 2004: 170-175.

[9] 王加阳, 谢颖. 基于量子粒子群优化的最小属性约简算法[J]. 计算机工程, 2009, 35(12)：148-150.
WANG Jia-yang, XIE Ying. Minimal attribute reduction algorithm based on quantum particle swarm optimizati-on[J]. Computer Engineering, 2009，35(12)：148-150.

[10] WANG Xiang-yang, YANG Jie, TENG Xiao-long. Feature selection based on rough sets and particle swarm optimization[J]. Pattern Recognition Leters, 2007, 28(4)：459-471.

[11] 程京, 等．一个基于差别矩阵的属性约简改进算法[J]．湖南大学学报：自然科学版，2009，36(4)：85-88.
CHENG Jing, et al. An updated algorithm for attribute reduction based on discernibility matrix[J]. Journal of Hunan University: Naturnal Science, 2009，36(4)：85-88.

[12] 张利, 等．基于粗糙集的启发式值约简的改进算法[J]. 仪器仪表学报, 2009(1)：82-85.
ZHANG Li, et al. Improved heuristic algorithm used in attribute value reduction of rough set[J]. Chinese Journal of Scientific Instrument, 2009(1)：82-85.

[13] ZHANG L, Lu X Y, WU H Y. An improved heuristic algorithm used in attribute reduction of rough set[C]// Proceedings of the First International Symposium on Data, Privacy and E-Commerce(ISDPE). 2007: 44-46.

[14] 徐凤生．一种属性与值约简及规则提取算法[J].计算机工程与科学, 2008(2)：61-63.
XU Feng-sheng. An attribute and value reduction and rule extraction algorithm[J]. Computer Engineering & Science, 2008(2)：61-63.

[15] 王英英．基于粗糙集与决策树的配电网故障诊断方法[J]．高电压技术，2008，34(4)：794-798.
WANG Ying-ying, et al. Fault diagnosis method for distribution networks based on the rough sets and decision tree theory[J]. High Voltage Engineering, 2008，34(4)：794-798.

[16] 孙卫祥, 等.基于 PCA 与决策树的转子故障诊断[J].振动与冲击，2007，26(3)：72-74.
SUN Wei-xiang, et al. Rotor fault diagnosis based on PCA and decision tree[J]. Journal of Vibration and Shock, 2007，26(3)：72-74.

[17] 高贇, 等．连续量信息表决策值的离散化方法[J]．西安科技大学学报, 2004，24(4)：486-488.
GAO Bin, et al. Discretization methods on decision values of successive quantity information table[J]. Journal of Xi'an University of Science and Technology, 2004, 24(4)：486-488.

[18] 王国胤．Rough 集理论与知识获取[M]．西安：西安交通大学出版社，2001.
WANG Guo-yin. Rough set theory and knowledge acquisition[M]. Xi'an: Xi'an Jiaotong University Press, 2001.

[19] Quinlan J R. Introduction of decision trees[J]. Machine Learning, 1986 (1)：84-100.

[20] 梁道雷, 等.一种多变量决策树方法研究[J].计算机科学，2008，35（1）：211-212.
LIANG Dao-lei, et al. A new multivariate decision tree algorithm[J]. Computer Science, 2008，35（1）：211-212.

收稿日期：2009-08-04；　修回日期：2009-09-30

作者简介：

张延松（1983-），男，硕士研究生，从事智能控制算法研究；E-mail: favourite200811@163.com

赵英凯（1943-），男，教授，博导，从事智能控制、机器人控制研究。

（上接第 54 页　continued from page 54）

[16] 王联国，洪毅. 随机交叉粒子群优化算法[J]. 计算机工程与应用，2009，45（16）：69-71.
WANG Lian-guo，HONG Yi. Stochastic crossover particle swarm optimization[J]. Computer Engineering and Applications，2009，45（16）：69-71.

收稿日期：2009-09-02；　修回日期：2009-11-16

作者简介：

董岳昕（1985-），女，硕士研究生，研究方向为电力系统无功优化、电能质量；E-mail:dyxscu@126.com

杨洪耕（1949-），男，教授，博士生导师，从事电能质量分析与控制、区域电压无功控制等方面的研究与教学工作。