

基于改进粒子群优化 BP 网络的发动机故障诊断方法*

张建军¹ 张利² 穆海芳² 刘征宇² 徐娟¹

(1. 安全关键工业测控技术教育部工程研究中心, 合肥 230009; 2. 合肥工业大学机械与汽车工程学院, 合肥 230009)

【摘要】 使用 BP 神经网络进行故障诊断过程中,随着输入变量的增加会造成“维数”灾难,导致训练效率不高,而且易陷入局部极小的问题。基于粗糙集的约简是常用的降低“维数”的方法,但约简是 NP 问题,随着信息量增多计算量会随之剧增;本文采用基于属性重要度的启发式值约简算法进行属性约简,建立了一种模糊信息知识发现方法结合粒子群优化 BP 网络的故障诊断方法。通过实验表明此方法不仅能有效获取规则,降低网络的输入维数,还能有效避免陷入局部极小,从而提高故障诊断的效率。

关键词: 发功机 粗糙集 粒子群优化 BP 神经网络 故障诊断 属性约简

中图分类号: TP206+.3 文献标识码: A 文章编号: 1000-1298(2011)01-0198-06

Improved BP-neural Network of the Particle Swarm Optimization in the Research on Engine Fault Diagnosis

Zhang Jianjun¹ Zhang Li² Mu Haifang² Liu Zhengyu² Xu Juan¹

(1. Engineering Research Center of Safety Critical Industrial Measurement and Control Technology, Ministry of Education, Hefei 230009, China 2. School of Machinery and Automobile Engineering, Hefei University of Technology, Hefei 230009, China)

Abstract

In the process of using BP-neural network in fault diagnosis, there will be “dimension tragedy” as the input variable increases, which causes the lower training effective. Besides, traditional BP algorithm tends to fall in local optimization. The reduction based on the rough set (RS) is the conventional “reduce dimension” method, but it is NP-hard problem, whose computing will gradually augment as the information increases. Therefore, a heuristic algorithm was used for attribute reduction based on the importance of attribute value to reduce attribute, a fault diagnosis approach was formed combining the fuzzy information system knowledge method with BP-neural network of the particle swarm optimization (PSO) algorithm to diagnose the fault of engine. The experiments show that comparing with the conventional method, it can not only require fault diagnosis rule, but also reduce net input dimensions effectively, avoid falling in local optimization and increase the efficiency of fault diagnosis.

Key words Engine, Rough set (RS), Particle swarm optimization (PSO), BP-neural network, Fault diagnosis, Attribute reduction

引言 点,粗糙集(RS)是处理含糊、不完备、不相容信息的有效数学工具,广泛应用于故障诊断规则获取,神经网络(NN)以其出色的数值逼近,处理定量的、数值发动机的故障呈现复杂性、多样性、非线性等特

收稿日期: 2010-01-29 修回日期: 2010-03-19
* 国家自然科学基金资助项目(60873003)、教育部博士点新教师基金资助项目(20080351025)和国家电子信息产业发展基金资助项目(2010301)
作者简介: 张建军,教授,博士,主要从事计算机控制、网络通信技术研究,E-mail: zjj@ialab.hfut.edu.cn
通讯作者: 张利,教授,主要从事机电一体化技术、计算机网络、数字化设计研究,E-mail: 77zhangli@hfut.edu.cn

化信息的能力,广泛应用于故障诊断系统中。采用神经网络进行故障诊断,而诊断过程涉及的元素种类较多时,网络结构模型复杂,影响诊断速度和精度^[1];使用基于粗糙集的约简,可减少神经网络的输入向量,但基于粗糙集的值约简算法是 NP-hard 问题,当属性值较多时,计算量明显大大增加;文献[2~4]采用的传统 BP 神经网络有收敛速度慢、使用梯度下降法易陷入局部极小的问题。

本文采用基于模糊粗糙集的模糊信息系统知识发现^[5]对训练样本进行属性约简,避免离散化造成的信息损失,采用改进的基于属性重要度的值约简算法提取规则,减少约简过程的计算量,简化输入神经元的维数,使用粒子群优化算法^[6]训练神经网络,可避免用梯度下降法导致算法收敛速度慢和易陷入局部极小问题。本文以某发动机供油系统为例,把经过模糊信息系统知识发现约简的条件属性进行规则获取,结合粒子群优化的神经网络进行故障诊断。

1 改进粒子群优化 BP 网络的故障诊断方法

1.1 诊断流程

集成粗糙集与神经网络的故障诊断首先是利用粗糙集约简神经网络的输入向量,然后经神经网络训练实例得到隐含层参数,最终建立神经网络实现故障诊断。故障诊断的关键是首先用模糊信息知识

系统发现方法得到约简属性,根据训练样本采用粒子群优化 BP 算法训练网络得到权值和阈值并保存,再将待诊样本输入网络即可得到诊断结果,诊断流程如图 1 所示。




图 1 诊断流程图

Fig. 1 Diagnosis flow

1.2 属性约简

基于粗糙集理论的属性约简方法是广泛应用于故障诊断的约简方法,由于粗糙集不能直接应用于连续变量的数据,而离散化会造成某些信息的损失,因此采用模糊信息系统知识发现方法进行属性约简,避免粗糙集约简前必须离散化而造成的信息损失。

以模糊不可区分关系为基础,把知识约简的概念推广到模糊环境中,用于模糊信息表的简化。不需要预先对原始数据集离散化,约简结果更能完整地反映原信息系统的内容。 $S = (U, A, V, f)$ 为一模糊决策信息系统,其中 $A = C \cup D$, C 为条件属性集, D 为决策属性集合,定义模糊集如下(其中 N 为映射)

$$f'_{c_{ij}} \begin{cases} \forall b \in C, t_b = 1 - N(b(x_i), b(x_j)) + \min_{b \in C} (N(b(x_i), b(x_j))) & (\min_{b \in D} (N(b(x_i), b(x_j))) = 0) \\ \phi & (\text{其他}) \end{cases} \quad (1)$$

其中

$$\forall a, b \in [0, 1] \begin{cases} N(a, b) = 1 & (a = b) \\ N(a, b) \in [0, 1] & (a \neq b) \\ N(a, b) = N(b, a) \\ N(a, c) \leq N(b, c) & (a \leq b \leq c, a \geq b \geq c) \end{cases}$$

模糊集构成的集合记为 $FM'(S)$,对于阈值 $\beta \in [0, 1]$,用公式 $FM'_\beta(S) = \{C'_{ij} = (f'_{c_{ij}})_\beta \mid \forall i, j = 1, 2, \dots, n\}$ 把集合 $FM'(S)$ 转变为 β -相对区分矩阵。 $FM'(S)$ 中任意非空元素 $C'_{ij} = \{a_1, a_2, \dots, a_k\}$,用 $\sum C'_{ij}$ 表示 $a_1 \vee a_2 \vee \dots \vee a_k$,记布尔区分函数为

$$\Delta^* = \begin{cases} \prod_{i,j=1}^n \sum C'_{ij} & (C'_{ij} \neq \emptyset) \\ 1 & (C'_{ij} = \emptyset) \end{cases} \quad (2)$$

函数 Δ^* 的极小析取范式中的合取式就是属性集 C 关于 D 的所有 β -相对约简。

1.3 值约简

属性约简后并不是最优约简,还可能存在冗余

的属性值,因此有必要进一步对属性值进行约简。本文采用基于属性重要度的启发式值约简算法进行属性值约简,值约简结果的质量可以由规则的置信度来判定。

1.3.1 决策质量规则

它能够评价依据该规则得到正确结论的概率估计,规则 if C_i then D_j 的置信度表示为

$$\mu(C_i, D_j) = K(C_i \cap D_j) / K(C_i) \quad (3)$$

其中 $K(C_i \cap D_j)$ 为满足规则前件 C_i 且规则后件为 D_j 的数目, $K(C_i)$ 为满足规则前件为 C_i 的数目。

置信度作为衡量决策规则的质量,说明了规则后件相对于规则前件的可信程度,即规则前件成立时,能够得到规则后件的概率。

1.3.2 基于属性重要度的值约简

将决策表中添加某个条件属性所引起的互信息大小作为属性重要度^[7],它利用条件属性与决策属性之间的互信息反映了属性对于决策的重要程度这个特点。

令 $S = (U, C \cup D, V, f)$ 是一信息系统, C 是条件属性, D 是决策属性, $c(x)$ 是记录 x 在属性 $c(c \in C)$ 上的值, $C(i, j)$ 表示可辨识矩阵中第 i 行第 j 列的元素, 则可辨识矩阵 C 表示为

$$C_{ij} = \begin{cases} c \in C & (c(x_i) \neq c(x_j), D(x_i) \neq D(x_j)) \\ 0 & (D(x_i) = D(x_j)) \end{cases} \quad (i, j = 1, 2, \dots, n) \quad (4)$$

如可辨识矩阵

$$\begin{pmatrix} 0 & c_{1,2} & \cdots & c_{1,n} \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & c_{m-1,n} \\ 0 & 0 & \cdots & 0 \end{pmatrix}$$

- 观察可以发现, 可辨识矩阵具有以下几个特点:
- (1) 可辨识矩阵中所有单个元素的属性均为核属性, 即矩阵元素中属性组合数为 1 的条件属性, 值核可以由属性约简后删除多余的条件属性值得到, 该属性必须保留。
 - (2) 可辨识矩阵中凡是条件属性组合中包含有核属性的矩阵元素都可以仅用核属性就能把不同的记录区分开来, 即包含有核属性的矩阵元素除核属性外的其他条件属性都是多余的。
 - (3) 不包含核属性的属性组合中至少有一个元素会成为约简集中的一个条件属性。
 - (4) 可辨识矩阵某一元素包含的属性个数越少, 则这个元素对分类的作用越大, 一个属性在矩阵中出现的次数越多, 表明该属性对于决策表的重要性越大。

在决策表中, 属性对于决策的重要程度反映在可辨识矩阵中, 根据某个条件属性在可辨识矩阵中出现频率作为该属性重要性的度量准则。属性重要度是对于值核外的条件属性而言, 对于值核外的每个属性, 采用遍历整个可辨识矩阵的方法, 分别记录它在可辨识矩阵中出现的次数。可构造出属性重要度函数为

$$f(c_i) = \sum_{m_{ij}} \frac{t_{ci}}{\text{card}(m_{ij})} \quad (5)$$

其中, $\text{card}(\ast)$ 表示该集合的元素数目, t_{ci} 是属性 c_i 在矩阵元素 m_{ij} 出现与否的标志, 取值为

$$t_{ci} = \begin{cases} 1 & (a_i \in m_{ij}) \\ 0 & (a_i \notin m_{ij}) \end{cases} \quad (6)$$

即启发式值约简算法获取故障规则。

1.4 改进的 BP 神经网络

1.4.1 BP 神经网络的构建

本文采用最常用的 3 层网络结构的 BP 网络模型, 构建神经网络模型的具体步骤: 输入层由模糊信息系统知识发现方法约简后的条件属性确定; 隐含

层节点数由自适应聚类中心选取学习算法确定; 用粒子群优化 BP 算法学习连接权值; 输出层由故障状态构成。网络拓扑结构如图 2 所示。




图 2 网络拓扑结构图
Fig. 2 Network topological graph

对于 BP 神经网络, 隐层神经元个数选择是比较困难的。一般总是选择训练样本集中每一个样本作为一个聚类中心, 即把训练样本的数量作为隐层神经元的个数。这样会造成网络结构非常庞大, 影响网络的训练效率和使用率。自适应聚类中心选取学习算法能够逐个地添加神经元, 并在当前样本集中选择对网络输出具有最大贡献量的样本作为该神经元的聚类中心。然后计算网络输出误差, 判断是否满足要求。如果满足, 则即为当前神经元个数; 否则, 再增加一个神经元, 重复以上步骤。该方法能够自适应地选择隐层神经元的个数及其聚类中心, 使网络在满足给定条件下, 网络的拓扑结构能达到最优。

1.4.2 粒子群优化 BP 神经网络

神经网络是通过对已有数据进行训练来确定网络的权值和阈值, 从而确定隐含层函数参数, 为最终的故障识别提供依据。BP 算法本质上是以误差平方和为目标函数、用梯度法求其最小值的算法, 除非误差平方和是正定的, 否则必然有局部极小点存在, 而粒子群算法属于随机寻优过程, 不存在局部收敛问题, 考虑用粒子群优化算法优化神经网络训练过程, 可有效避免陷入局部最优。

粒子群优化算法 (PSO) 是一种基于迭代的进化计算优化工具。粒子 i 的信息用 d 维向量表示, 位置为 $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{id})^T$, 速度为 $\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{id})^T$ 。速度和位置更新公式为

$$v_{id}^{k+1} = wv_{id}^k + \phi_1 p_{bestid}^k - \phi_1 x_{id}^k + \phi_2 g_{bestid}^k - \phi_2 x_{id}^k \quad (7)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (8)$$

式中 v_{id}^k ——粒子 i 在第 k 次迭代中第 d 维的速度
 w ——惯性因子
 ϕ_1, ϕ_2 —— $[0, 1]$ 内的随机数
 x_{id}^k ——粒子 i 在第 k 次迭代中第 d 维的位置
 p_{bestid}^k ——粒子 i 在前 k 次迭代中第 d 维的个体最优位置

g_{bestd}^k ——整个种群在前 k 次迭代中第 d 维的全局最优位置

基于粒子群优化算法在解空间内搜索时,为避免粒子在全局最优解附近出现“振荡”现象,因此作如下改进^[9]:随着迭代进行,速度更新公式中的加权因子 w 由 w_{max} 线性减小到 w_{min} ,即(其中 $iter$ 是当前迭代数, $iter_{max}$ 是总的迭代次数)

$$w = w_{max} - iter \frac{w_{max} - w_{min}}{iter_{max}} \quad (9)$$

粒子的适应度函数可以被定义为一次迭代所有样本误差的平方和^[10],即

$$J(d) = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M (Y_{i,j} - y_{i,j})^2 \quad (10)$$

式中 N ——训练样本总数

M ——网络输出神经元个数

$Y_{i,j}$ ——第 i 个样本的第 j 个输出节点的目标输出

$y_{i,j}$ ——第 i 个样本的第 j 个输出节点的实际输出

粒子种群数 L ,若神经网络共有 d 个神经元, n 个输出层神经元, m 个隐含层神经元,则粒子群算法的维数为

$$D = dm + mn + m + n \quad (11)$$

初始化粒子群矩阵 $\begin{pmatrix} x_{id} & \cdots & v_{id} & \cdots & J_d \\ \cdots & & \cdots & & \cdots \\ \cdots & & \cdots & & \cdots \end{pmatrix}$,粒

子位置 x_{id} 共有 L 列,速度 v_{id} 共有 D 列,最后一列为适应度。实现该算法的步骤如图 3 所示。

由于粒子群算法代替了神经网络的初始寻优,神经网络初始化前已经接近最优解,它仅在全局最优解的基础上进行参数寻优,因此可以提高网络的寻优速度,避免其陷入局部最优。

2 诊断实例

以某发动机供油系统做实验分析,发动机内部存在着众多的激励源,这些激励源最终都会反映为表面的振动响应,通过提取缸盖或缸体上的振动信号获取发动机进行故障诊断规则。根据燃油压力的时域振动信号,利用小波变换分析,从小波分解逼近信号中选择时域特征参数: $A = \{A_1, A_2, \cdots, A_{11}\}$ 为故障征兆集, A_1 为压力上升缓慢, A_2 为压力急剧上升, A_3 为开启压力提前, A_4 为开启压力滞后, A_5 为高峰值压力, A_6 为低峰值压力, A_7 为关闭提前, A_8 为关闭滞后, A_9 为高反射压力, A_{10} 为低反射压力, A_{11} 为二次喷射; $D = \{D_1, D_2, D_3, D_4\}$ 为故障集合, D_1 为喷油嘴堵塞, D_2 为喷油嘴滴油, D_3 为油管堵塞, D_4 为柱塞磨




图 3 粒子群优化 BP 神经网络算法
Fig.3 BP-neural network of the PSO algorithm

损。得到发动机供油系统输入特征量和输出故障间关系的 9 个样本,见表 1,表中对应的模糊相对区分矩阵 $\{X_1, X_2, \cdots, X_9\}$ 为

$$\begin{pmatrix} 0 & \cdots \\ A_1 A_2 A_3 A_5 A_9 & 0 & \cdots \\ A_2 A_5 A_9 A_{11} & A_2 A_5 A_6 & 0 & \cdots \\ A_1 A_5 A_9 A_{10} & A_2 A_7 & A_3 A_5 A_6 A_9 & 0 & \cdots \\ \vdots & \vdots & \vdots & \vdots & 0 & \cdots \\ A_1 A_2 A_7 A_9 A_{11} & A_4 A_8 & A_3 A_4 A_8 A_{11} & A_1 A_7 A_9 A_{11} & \cdots & 0 \end{pmatrix}$$

关于条件属性相似度量算子^[4]取 $N(a, b) = 1 - |a - b|$;决策属性的相似度量算子取的最小属性约简,约简后的条件属性值只有 6 个,基于属性重要度的求值约简启发式^[7]算法获取故障诊断规则;同时确定 BP 网络输入层为 6 个节点,对应于供油系统正常,喷油嘴滴油,油管堵塞,柱塞磨损 4 种状态,输出层为 4 个节点。采用自适应聚类中心选取学习算法获取隐含层神经元数目 5,用粒子群优化 BP 网络训练隐含层节点,获取权值和阈值。

$$N(a, b) = \begin{cases} 0 & (a \neq b) \\ 1 & (a = b) \end{cases} \quad (\beta \approx 0.7619)$$

可见, $\{A_1, A_3, A_9\}$ 是 $\beta \approx 0.7619$ 模糊相对核,条件属性关于决策属性的最小约简不只一个,考虑到征兆获取的难易,本文选择 $\{A_1, A_3, A_4, A_8, A_9, A_{11}\}$

表 1 供油系统正常与故障时的燃油压力振动特征参数

Tab.1 Vibration characteristic parameters of oil supply system in normal and fault situation

样本	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8	A_9	A_{10}	A_{11}	D
1	-1.11	0.21	0.18	-1.02	0.91	-0.19	0.98	0.09	-0.09	0.91	-0.19	D_2
2	-1.02	0.11	-0.21	-1.19	0.89	-0.11	0.81	1.09	-0.10	0.98	-0.05	D_2
3	-1.20	0.19	0.16	-0.89	0.97	-0.09	0.90	0.98	-0.01	0.89	-0.08	D_3
4	-1.21	0.16	0.09	-0.96	1.02	-0.18	1.01	1.03	-0.11	1.08	1.08	D_4
5	-1.02	0.09	-0.13	1.10	1.01	1.05	-0.09	0.01	-0.19	0.09	0.98	D_3
6	-1.10	-0.11	0.18	1.19	1.00	1.01	-0.10	0.10	0.09	0.19	0.04	D_1
7	-1.09	-0.17	0.11	1.07	0.95	1.10	-0.07	0.09	0.99	0.14	0.01	D_1
8	-1.20	-0.10	-0.13	1.05	1.02	1.08	-0.08	0.19	0.91	0.04	0.21	D_3
9	-1.30	-0.08	0.14	1.09	0.90	1.06	-0.11	0.20	1.05	0.13	0.16	D_4

作为诊断决策其网络拓扑结构,如图 4 所示。

所示。




图 4 供油系统故障诊断网络拓扑结构

Fig.4 Fault diagnosis network topological graph of oil supply system

3 实例分析

本文实例数据,与文献[7]基于属性重要度的启发式值约简算法(把在决策表中添加某个条件属性所引起的互信息大小作为属性重要度)获取的诊断规则比较结果如表 2 所示。

表 2 算法比较

Tab.2 Algorithm comparison

算法	决策规则数	规则平均长度	规则置信度
文献[7]	5	2.50	1
本文	4	2.25	1

由表 2 可见,本文算法得出的决策规则数目少,平均长度短,置信度均为 1,说明本文的规则获取方法取得了较好的效果。

在训练精度为 0.5% 的情况下,分别用本文的方法与文献[2~4]的方法训练神经网络,它们降低网络输入维数的方法都是经离散化后再进行约简属性,文献[2]采用的是模糊神经网络,文献[3]采用的是传统的 BP 神经网络,文献[4]采用的是集成神经网络,训练过程、网络收敛曲线图分别如图 5、图 6




图 5 训练过程

Fig.5 Training process




图 6 收敛对比曲线

Fig.6 Compared figure of convergence curves

由图 6 可知 BP 算法收敛速度慢,收敛过程出现波动现象,说明其易于陷入局部最小,而粒子群优化 BP 算法收敛曲线平稳无振荡,比 BP 算法稳定,不易陷入局部最小,并有较快的收敛速度。训练结果与 100 个待诊样本的测试结果分析如表 3 所示。

表 3 比较分析

Tab.3 Comparison and analysis

诊断方法	训练结果			测试结果	
	时间/s	训练次数	误差	识别率/%	诊断精度/%
文献[2]	9.10	1 121	0.15	3.0	95.0
文献[3]	8.78	1 015	0.12	2.4	96.3
文献[4]	7.98	997	0.13	1.8	96.8
本文	1.21	706	0.07	1.1	98.9

通过模糊信息知识发现约简属性,在保证故障识别率的情况下,减少了神经网络的输入变量,有效避免了“维数灾难”问题,采用粒子群优化的 BP 网络,在保证故障诊断精度情况下,减少了网络训练次数,提高了网络学习速率,避免了陷入局部极小问题。

4 结束语

基于 BP 神经网络的发动机故障诊断的研究分

析,提出了一种改进的基于粗糙集与神经网络的故障诊断方法,对神经网络的输入向量进行约简,降低网络输入维数,采用模糊信息知识发现方法进行属性约简,避免了离散化造成的信息损失,利用粒子群优化算法优化现有的 BP 神经网络,避免了网络易陷入局部极小问题,从而在保证正确率的基础上提高了诊断效率。

参 考 文 献

1

吴宗彦,韩煜,张建军,等. 基于模糊神经网络的自动生产线故障诊断方法研究[J]. 中国机械工程,2008,19(9): 1 072 ~ 1 075.

Wu Zongyan, Han Yu, Zhang Jianjun, et al. Research on auto-production line fault diagnosis based on FNN[J]. China Mechanical Engineering, 2008,19(9):1 072 ~ 1 075. (in Chinese)

2

罗艳春,郭立红,康长青,等. 用粗糙-模糊神经网络评定空袭目标威胁程度[J]. 光电工程,2008,35(3):10 ~ 15.

Luo Yanchun, Guo Lihong, Kang Changqing, et al. Assessing threat degree of aerial target by applying rough sets and fuzzy neural networks [J]. Opto-electronic Engineering, 2008,35(3):10 ~ 15. (in Chinese)

3

李增芳,何勇. 基于粗糙集与 BP 神经网络的发动机故障诊断模型[J]. 农业机械学报,2005, 36(8):118 ~ 121.

Li Zengfang, He Yong. Study on fault diagnosis model of misfire in engines based on rough set theory and neural network technology [J]. Transactions of the Chinese Society for Agricultural Machinery, 2005,36(8): 118 ~ 121. (in Chinese)

4

文振华,左洪福. 基于粗糙集-集成神经网络的航空发动机磨损故障诊断方法[J]. 中国机械工程, 2007, 18(21): 2 580 ~ 2 584.

Wen Zhenhua, Zuo Hongfu. A diagnosis method for aero engine wear fault based on rough sets theory and integrated neural network [J]. China Mechanical Engineering, 2007, 18(21):2 580 ~ 2 584. (in Chinese)

5

刘燕,李世其,段学燕. 模糊信息系统知识发现方法在油液监测故障诊断中的应用[J]. 内燃机学报,2008, 26(4): 374 ~ 378.

Liu Yan, Li Shiqi, Duan Xueyan. Applying method of knowledge discovery to oil monitoring and fault diagnosis based on fuzzy rough set[J]. Transactions of CSICE, 2008, 26(4):374 ~ 378. (in Chinese)

6

杨海龙,孙健国. 粒子群优化的粗糙集-神经网络在航空发动机故障诊断中的应用[J]. 航空动力学报,2009,24(2): 458 ~ 464.

Yang Hailong, Sun Jianguo. Application of PSO based rough set theory and neural network to acro engine fault diagnosis[J]. Journal of Aerospace Power, 2009,24(2):458 ~ 464. (in Chinese)

7

张利,卢秀颖,吴华玉,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, 30(1):82 ~ 85.

Zhang Li, Lu Xiuying, Wu Huayu, et al. Improved heuristic algorithm used in attribute value reduction of rough set [J]. Chinese Journal of Scientific Instrument,2009, 30(1):82 ~ 85. (in Chinese)