

文章编号: 1000-8055(2008)12-2170-07

基于神经网络规则提取的航空发动机 磨损故障诊断知识获取

陈 果¹, 宋兰琪², 陈立波²

- (1. 南京航空航天大学 民航学院, 南京 210016;
2. 北京航空工程技术研究中心, 北京 100076)

摘 要: 针对神经网络智能诊断与专家系统中知识难于理解和诊断解释能力差等问题, 研究了一种新的基于功能性观点的神经网络规则提取方法, 介绍了方法流程及关键算法. 并用 UCI(加利福尼亚大学埃尔文分校)机器学习数据对方法进行了分析和验证. 最后, 将方法应用于实际航空发动机磨损故障诊断中, 采集了某型航空发动机实测油样光谱数据 237 个样本, 利用神经网络规则提取方法提取了发动机磨损故障诊断知识规则, 并对其进行了解释, 结果表明了方法的正确有效性.

关 键 词: 知识获取; 故障诊断; 磨损; 神经网络; 规则提取

中图分类号: TH165.3; TP183; TP391; TH17

文献标识码: A

Knowledge acquisition for aero-engine wear fault diagnosis based on rule extraction from neural networks

CHEN Guo¹, SONGLan-qi², CHEN Li-bo²

- (1. Civil Aviation College,
Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;
2. Beijing Aeronautical Technology Research Center, Beijing 100076, China)

Abstract: In view of the problem that it is difficult to understand the knowledge and diagnosis process in intelligent and expert systems based on neural network, a new rule extraction method from neural network based on the functional point of view was studied, and the flow and the key algorithms of the new method were introduced. The UCI (University of California Irvine) machine learning data were used to analyze and verify the rule extraction method. Finally, this method was applied to aero-engine wear faults diagnosis. 237 spectral oil analysis samples were acquired from practical aero-engine, the rules extraction from NN (Neural networks) method was used to extract the diagnosis knowledge rules, the extracted rules were explained and analyzed. The results fully show the correctness and rationality of the new method.

Key words: knowledge acquisition; fault diagnosis; wear; neural network;
rules extraction

收稿日期: 2007-11-26; 修订日期: 2008-03-31

作者简介: 陈果(1972-), 男, 四川武胜人, 教授、博士生导师, 主要从事航空发动机状态监测与故障诊断、非线性非转子动力学、智能诊断与专家系统、机器学习与知识获取、图像处理及模式识别等领域研究.

航空发动机的磨损故障诊断主要是通过监测发动机滑油中的金属和非金属磨粒的含量、浓度、尺寸、形状和颜色等信息来诊断发动机传动系统摩擦副的磨损性质、磨损类型和磨损部位^[1]。由于故障征兆和故障原因之间往往存在复杂的非线性关系,具有模糊性、随机性和不完备性等不确定性特征,因此神经网络由于其优越的非线性映射能力和超强的容错性,在磨损故障诊断中得到了广泛的应用^[2-4]。

然而,由于神经网络获取的知识蕴涵在大量的连接权中而难以理解和解释,因此,从训练好的神经网络中提取知识规则,是神经网络智能诊断和神经网络专家系统的迫切需求。目前国内外学者对神经网络规则提取进行了大量的研究,Gallant^[5]基于推理强度对可用属性进行排序,从而构造出可以解释网络如何为某个给定事例产生结论的规则。Saito Nakano^[6]令网络输入逐渐改变,通过检查网络的激活度来构造候选规则集并从中寻找有用的规则。Fu^[7]搜索节点的扇入连接权,通过找出权值之和超过阈值的连接权子集来抽取规则。周志华等^[8]从功能性观点出发,提出了一种统计的神经网络规则提取方法 SPT,但是该方法的复杂性较高,而且在使用过程中需要进行人为干涉,难于实现规则的自动提取。主要表现在两方面,其一,在对连续属性的离散化处理中,寻找聚类效果好的属性进行离散,本身就是比较困难且难于用计算机自动实现的问题,其二,在神经网络训练中,神经网络本身的泛化能力优劣也往往依靠人为判断。

有鉴于此,本文通过引入粗糙集理论及数据挖掘中的相关技术,提出新的基于功能性观点的神经网络规则提取方法。介绍了新方法的流程和关键技术,最后,本文将新的神经网络规则提取方法应用于实际航空发动机磨损故障诊断和知识规则获取。

1 神经网络规则提取新方法

1.1 方法流程

与结构分析方法不同,基于功能性分析的神经网络规则提取方法并不对神经网络结构进行分析和搜索,而是把神经网络作为一个整体来处理,即把神经网络看成“黑箱”。这类方法更注重的在功能上对神经网络的重现能力,即产生可以替代原来网络的规则。通常,用训练好的神经网络对一个示例的输入模式进行判别,并将其判别结果作

为输出模式,则与该输入模式一起组成一个完整示例,显然,该示例就在一定程度上反映了网络在示例空间中该点上的响应特性,如果这种示例数目足够多,并且比较均匀地覆盖整个示例空间,则从该示例集中抽取的规则将具有与原神经网络相似的使用效果,即这些规则可以描述原网络的功能。这就是基于功能性观点的神经网络规则提取原理。

本文在现有研究的基础上,通过引入粗糙集理论和数据挖掘技术,提出一种新的基于功能性观点的神经网络规则提取方法,该方法流程如图 1 所示。对属性进行特征选取以简化计算;对所有属性(包括连续和离散)进行统一离散化处理,并保留断点;神经网络结构的结构与优化,获取最佳泛化能力的神经网络;利用所得到的神经网络产生示例样本;最后从示例样本中提取出知识规则,并存入知识库。本文方法的特点在于:引入了粗糙集理论中由 Nguyen S H 和 Skowron 提出的布尔逻辑与粗糙集理论相结合的经典离散化方法^[9],该方法可以将离散属性看作连续属性的特例,同时进行处理,这在很大程度上降低了计算的复杂性;在神经网络结构设计中,采用了结构自适应神经网络模型^[10]以保证训练好的神经网络具有最佳的泛化能力;在规则提取中,提出了一种分层穷举式的规则提取方法,保证了规则提取的完整性和优先次序。下面对其中的关键技术进行介绍。

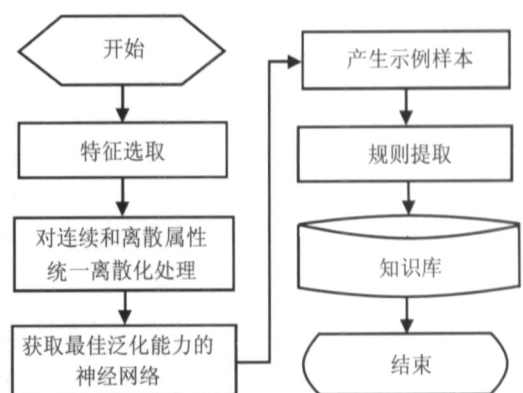


图 1 神经网络规则提取流程

Fig. 1 Rule extraction flow of neural networks

1.2 关键技术

1) 特征排序与选取

特征排序与选择对于减少数据特征的冗余、优先提取出重要规则以及提高计算效率具有重要意义,本文将特征选取作为神经网络规则提取的

第一步,首先根据数据特征重要性排序,然后依据排序结果,对特征进行适当删减.本文采用文献[11]的基于熵的特征选取方法.该方法的基本思路是,将属性逐一去除,观察集合的熵变化,如果特征越重要,去除后,集合的熵将变化很大,因此,特征重要性指标值也越大.由此可见,可以根据特征重要性指标对特征进行排序.规定一个适当的阈值,当特征重要性指标小于阈值时,即可将特征集合 F 中删除,从而实现特征选取.

2) 离散化处理

由于粗糙集理论^[12-13]不需要先验知识便可完全从数据或经验中获取知识,因此,本文引入粗糙集理论中的离散化理论进行离散化处理.离散化本质上可归结为利用选取的断点来对条件属性构成的空间进行划分的问题.如果仅仅考虑单个属性,经过离散化后,可能将引入冲突.而由 Nguyen S H 和 Skowron 提出的布尔逻辑与粗糙集理论相结合的离散化方法^[9],是粗糙集理论中离散化思想的重大突破,其基本思想是首先在保持信息系统的不可分辨关系不变的前提下,尽量以最小数目的断点把所有实例的分辨关系区分开,因此,离散化后数据集不会引入冲突.由于求最小数目的断点集是 NP 完全问题,因此只能寻找近似最优的算法来求得最小数目的断点集.在文献[9]中,Nguyen S H 和 Skowron 采用启发式算法(贪心算法)来求得最小数目的断点集.此算法具体步骤见文献[9,13].

3) 神经网络设计

在基于神经网络的知识获取和规则提取研究中,针对具体的样本数据,设计出具有最大泛化能力的最优网络结构至关重要.本文利用作者在文献[10]提出一种结构自适应神经网络模型,能够从给定样本中自动设计出具有最佳泛化能力的神经网络模型.其基本原理阐述如下.

结构自适应神经网络模型以 3 层 BP 网络为研究对象.将神经网络模型分为外部结构参数和内部权值参数.规定为:1) 内部参数,网络连接权值,通过对训练样本用神经网络的 BP 算法学习成功后自动产生.2) 外部参数,初始权值,影响网络的收敛位置;隐层节点数,直接影响到所逼近的非线性函数复杂程度和模型的泛化能力;训练步数,对网络泛化能力具有很大的影响,网络训练步数越多,网络结构越复杂,泛化能力往往将变得很差.

结构自适应神经网络模型的基本思想为,首

先,在样本集中对 N 个样本迭加 10% 的随机噪声,每个样本产生 M 个新的样本,一共产生 $M \times N$ 个新样本,形成神经网络训练集.按同样方法得到 $M \times N$ 个新样本作为测试集.利用神经网络的 BP 算法对训练样本集进行学习,获取模型的内部连接权值参数.再利用测试样本集,对学习模型进行测试,并计算识别误差,形成遗传算法的适应度函数;然后运用遗传算法的学习机制,自动调节神经网络模型的外部结构参数,最后通过逐代进化,得到具有最优泛化能力的神经网络模型.

其中,关于训练样本和测试样本的产生方法为:对第 i 个样本;第 j 个特征;产生 0-1 分布的随机噪声,叠加到第 i 个样本,第 j 个特征值上,形成一个新的样本,重复 M 次,则得到 M 个样本; $i = i + 1$,转至 ,直到 $i = N$,结束.最终产生 $M \times N$ 规定噪声强度的样本.

4) 示例样本产生

通过优化后获取的神经网络模型应该具有较强的泛化能力,因此,如果用原始数据集训练出一个神经网络,再利用该神经网络产生一个数据集,则该数据集将比原始的数据集包含更多的有助于预测的信息.假设现有一个训练好的神经网络 ANN,如果用 ANN 对输入模式 $A_k = (a_1, a_2, \dots, a_n)$ 进行判别,则神经网络将产生与 A_k 对应的输出模式 $C_k = (c_1, c_2, \dots, c_q)$,其中 n 为输入属性数, q 为输出分类数.将 A_k 和 C_k 组合起来就可以得到一个示例样本 (A_k, C_k) ,如果有很多这样的示例样本,就得到了一个示例样本.

示例样本可以通过在实例空间中缓慢移动 A_k 而产生,即对每一个输入属性 $a_i (i = 1, 2, \dots, n)$,令其值在取值范围内逐渐变化,使得尽可能的值得以出现.本文示例样本的产生连续属性离散和神经网络训练之后,均是针对离散属性,因此,只需对 a_i 的值进行列举即可.

示例样本的具体产生方法为:首先确定输入属性的取值范围,然后在该范围内生成一个随机数据集,原始的训练集也被加入到该数据集中;然后,由训练好的神经网络对该数据集进行判别,以产生相应的输出;最后再将输入和输出进行结合即得到规则学习部分所用的示例样本.实验结果表明:当随机数据集中的个数为原样本数的 5 倍,可以获得相当好的规则,由于这个实例集是用由神经网络产生的,所以实例集能够体现神经网络的分类功能.

5) 规则提取

为了从数据中提取出更多的满足一定可信度的知识规则,同时规则具有更大的适应性(即泛化能力),本文提出了分层穷举式规则提取方法.该方法的基本思想是优先提取出属性数目最少的满足给定可信度和覆盖度的规则,在实施过程中,按属性数目由少到多进行分层,在每层中进行属性穷举组合,并依次提取知识规则.算法的具体描述为

算法输入:决策表 $S = [U, R, V, f]$, 其中 U 是论域, $R = C \cup \{d\}$ 是属性集合,子集 C 和 $\{d\}$ 分别称为条件和决策属性集,条件属性数目为 m ,决策属性数目为 1,可信度阈值为 T 和覆盖度阈值 F ,属性总数为 N_{MAX} .

算法输出:可信度大于 T 且覆盖度大于 F 的规则集.

STEP1:算法输出条件属性数 NC 从 1 开始到 N_{MAX} 进行下列循环计算.

STEP2:在第 NC 层,首先进行属性组合,属性组合的数目为 C_m^{NC} , 设 $\{c_{i_1}, \dots, c_{i_{NC}}\}$ 为第 i 个属性组合 ($i = 1, 2, \dots, C_m^{NC}$). 令 $C^* = \{c_{i_1}, \dots, c_{i_{NC}}\}$, 即条件属性集 C^* 对决策表 S 的划分 $E_{(K, C^*)}$, 其中 $E_{(K, C^*)}$ 属于 $\{U \mid IND(C^*)\}$, $K = 1, \dots, |\{U \mid IND(C^*)\}|$. 如果某个划分 $E_{(K, C^*)}$ 对特定决策(如 X_j)的可信度超过给定阈值 T , 即 $\mu_{C^*}(E_{(K, C^*)}, X_j) = \frac{|E_{(K, C^*)} \cap X_j|}{|E_{(K, C^*)}|} > T$ (1)

则得到规则

$$Des(E_{(K, C^*)}, C) \rightarrow Des(X_j, D) \quad (2)$$

其中 $|E_{(K, C^*)} \cap X_j|$ 为该规则在决策表中的绝对覆盖度,表示决策表中同时满足该规则前件和后件的实例数; $|E_{(K, C^*)}|$ 为决策表中满足该规则前件的实例数; $|E_{(K, C^*)} \cap X_j| / |E_{(K, C^*)}|$ 为该规则的可信度. 设示例样本总数为 N , 则定义 $|E_{(K, C^*)} \cap X_j| / N$ 为该规则在决策表中的相对覆盖度,如果相对覆盖度大于给定阈值 F , 则该规

则有效,否则无效,即该规则不放入规则集合中.

将原始决策表 S 中满足该条规则条件的实例删除,得到新的决策表 $S = [U, R, V, f]$, 其中 $U = \{x \mid x \in U, c_{i_1}(x) = i_1, \dots, c_{i_{NC}}(x) = i_{NC}\}$. 显然,随着规则的不断提取, S 的实例规模将远小于 S .

STEP3:如果 $U = \emptyset$, 则转入 STEP4. 否则,令 $S = S$, $NC = NC + 1$, 如果 $NC > N_{MAX}$, 则转入 STEP4. 否则转入 STEP2;

STEP4:输出所有规则集. 计算结束.

显然,可信度和覆盖度阈值对规则提取结果具有很大的影响,本文以 UCI 机器学习数据库的 IRIS 数据为例进行分析,在对 IRIS 数据进行离散化处理、神经网络训练以及示例样本生成后,利用本文分层穷举式规则提取算法从示例样本集提取出规则集,对原始样本集引入 10% 的随机噪声,形成 150 个测试样本,利用测试样本可以对所提取出的规则集进行测试. 表 1 为不同可信度和覆盖度阈值下,所提取的规则对测试样本的识别结果. 从表 1 可以看出,本文方法可以自由调整可信度和相对覆盖度,从而得到不同精度和规模的规则集,如果可信度小于 1 将得到不确定性规则,增大相对覆盖度阈值将得到更为简洁的规则集,因此在实际应用中非常方便. 通常,可信度阈值区间为 $[0.8, 1.0]$, 覆盖度阈值区间为 $[0, 0.05]$.

1.3 方法验证

为了验证本文方法的有效性,本文利用国际上权威的 UCI(University of California Irvine)机器学习数据库中的 6 个数据集对本文算法进行实验测试. 实验中采用目前最流行的 10 折交叉验证准则(10-fold cross validation)来比较和评价算法,即将初始样本集划分为 10 个近似相等的数据子集,每个数据子集中属于各分类的样本所占的比例与初始样本中的比例相同,在每次实验中用其中的 9 个数据子集组成训练样本,用剩下的一个子集作为测试集,轮转一遍进行 10 次实验.

表 1 不同可信度和覆盖度阈值对规则提取结果的影响

Table 1 Effect of reliability and coverage range on the rule extraction results

可信度阈值 T	1.00			0.90			0.80		
覆盖度阈值 F	0.00	0.02	0.04	0.00	0.02	0.04	0.00	0.02	0.04
识别率	0.95	0.93	0.91	0.95	0.93	0.91	0.95	0.93	0.93
规则数	21	14	10	16	11	7	11	8	6

为了进行比较,利用相同的数据集,本文也对粗糙集理论和决策树 ID3 算法的规则提取方法进行了 10 折交叉验证测试. 实验结果如表 2 所示. 对连续属性的离散算法均采用文献[9]的贪心算法,在粗糙集算法中,属性约简均采用文献[13]的辨识矩阵法进行,在规则提取中,分别采用文献[14]的启发式值约简方法、文献[15]的归纳值约简方法以及本文的分层穷举式方法. 从表 2 的实验结果,通过可以得出以下结论:

1) 神经网络规则提取方法,充分利用了神经网络的泛化能力,因此,从训练好的神经网络中产生出的示例样本中提取出的规则也将更好的描述和表达原始数据集的知识信息. 从表 1 可以看出,对于相同的数据集,神经网络规则提取方法得到的规则集具有更高的精度. 值得注意的是,粗糙集规则提取方法中,采用本文分层穷举法得到的规则,其 10 折交叉验证的平均识别率均比本文神经网络方法提取出的规则要低,由于两种方法的离散和规则提取方法均相同,故更加具有可比性,显然,结果进一步表明了神经网络泛化能力能够保证提取出的高精度的规则.

2) 从表 2 中可以看出,对于相同的数据集,对比文献[14]的启发式值约简方法和文献[15]的归纳值约简方法,利用本文的分层穷举式规则提取法得到的规则集具有更高的精度. 因此,该比较结果也充分验证了本文提出的分层穷举式规则提取方法的正确有效性.

表 2 不同方法的 10 折交叉验证结果
Table 2 10-fold cross validation results

数据集	粗糙集方法				ID3
	本文方法	文献[14]	文献[15]	分层穷举法	
Iris	0.94	0.92	0.93	0.93	0.89
ACT	0.88	0.48	0.73	0.80	0.70
Hepatitis	0.80	0.55	0.68	0.78	0.69
Ecoli	0.79	0.47	0.39	0.65	0.63
Glass	0.62	0.34	0.21	0.48	0.26
HSV	0.66	0.34	0.40	0.45	0.44

2 神经网络规则新方法在航空发动机磨损故障诊断中的应用

本文以某军用航空发动机油样光谱分析数据

为例,将神经网络规则提取新方法应用于发动机磨损故障诊断的知识获取. 该数据包含了 10 台航空发动机在正常状态下和磨损状态下的 237 个样本. 原始数据见文献[16]. Fe, Al, Cu, Cr, Ag, Ti, Mg 七种元素的含量作为样本实例的条件属性,磨损状态“ F ”分为:“正常状态”、“轴间轴承磨损”、以及“轴间轴承磨损且保持架断裂”.

表 3 为各属性的熵的变化量计算结果,由于熵的变化量最大意味着属性的重要性越大,显然,可以看出,属性的重要性依此为: Mg, Ag, Cu, Fe, Ti, Al, Cr. 表 4 为数据离散化结果. 从表中可以看出,Fe 具有 2 个断点,将属性分为 3 个区间、Mg 具有 1 个断点,将属性分为 2 个区间. 其他属性无断点,因此对分类无任何影响. 表 5 为通过自适应神经网络得到的最优神经网络结构参数. 表 6 为所提取的规则集. 其中

1) 规则 $(0.20 < Fe < 7.00) \Rightarrow$ 正常状态,表示当油样中铁元素含量很低时,表明系统磨损正常磨损状态;

2) 规则 $(7.00 < Fe < 17.40) \Rightarrow$ 轴间轴承磨损及 $(0.40 < Mg < 1.45) \& (17.40 < Fe < 32.3) \Rightarrow$ 轴间轴承磨损,表示油样中铁元素含量升高,但镁元素含量在较低的水平时,发动机轴间轴承磨损严重;

3) 规则 $(1.45 < Mg < 16.9) \& (17.40 < Fe < 32.3) \Rightarrow$ 轴间轴承磨损且保持架断裂,表示油样中铁元素含量升高,同时镁元素含量也增高,发动机轴间轴承磨损严重且保持架断裂.

表 3 属性重要性

Table 3 Attribute importance

属性	Fe	Al	Cu	Cr	Ag	Ti	Mg
熵变化量	219	114	450	109	624	175	2610

表 4 离散化断点结果

Table 4 Discretizing results

属性	Fe	Al	Cu	Cr	Ag	Ti	Mg
断点值	7.00, 17.40,	—	—	—	—	—	1.45

对原始样本集引入一定强度的随机噪声,形成 237 个测试样本,利用该 237 个测试样本对所提取出的规则集进行测试. 表 7 为利用所提取的规则对不同噪声强度下的样本集测试结果. 从

结果可以看出,所提取的规则具有很高精度,且受噪声干扰很小,从而验证了本文方法的有效性.

表 5 最优神经网络结构参数

Table 5 Optimum structure parameters for Neural networks

输入层 节点数	中间层 节点数	最大训练 步数	权值随机 种子	训练 误差
2	5	50	0	0.001

表 6 提取的规则集

Table 6 Rules which are extracted from Neural networks

规则号	规则集
R1	$(0.20 < Fe < 7.00) \Rightarrow$ 正常状态 [1.00][481,481]
R2	$(7.00 < Fe < 17.40) \Rightarrow$ 轴间轴承磨损 [1.00][239,239]
R3	$(0.40 < Mg < 1.45) \& (17.40 < Fe < 32.3) \Rightarrow$ 轴间轴承磨损 [1.00][159,159]
R4	$(1.45 < Mg < 16.9) \& (17.40 < Fe < 32.3) \Rightarrow$ 轴间轴承磨损且保持架断裂 [1.00][179,179]

表 7 规则验证结果

Table 7 Verification results for rules

噪声强度/ %	数据数	正确数	误识数	拒识数	识别率/ %	误识率/ %	拒识率/ %
0	237	237	0	0	100	0	0
20	237	235	2	0	99.16	0.84	0
40	237	230	7	0	97.05	2.95	0
60	237	219	19	0	92.41	7.59	0
80	237	213	24	0	89.87	10.13	0
100	237	208	29	0	87.76	12.24	0

需要指出的是,本文知识规则均是直接从样本数据中提取出来,未考虑故障诊断的许多先验知识,如光谱元素的重要性、磨损界限值以及摩擦副的材质成分等,因此,规则的正确性和适用性完全取决于原始样本的完整性和代表性.如何将本文方法与先验知识结合?如何进一步收集整理发动机磨损故障的样本?如何进一步运用与实际发动机磨损故障诊断?需要进一步深入研究.

3 结 论

1) 提出了一种新的基于功能性观点的神经网络规则提取方法,阐述了连续属性的离散化处理、神经网络训练样本产生、神经网络结构优化、示例样本的产生以及规则提取等关键技术的理论与方法.并用 UCI 机器学习数据进行了分析和验证,表明了本文神经网络规则提取方法的有效性.

2) 将该神经网络规则提取新方法应用于航空发动机磨损故障诊断中,首先,采集实际航空发动机油样光谱数据 237 个故障样本,然后用神经网络规则提取方法得到了发动机磨损故障的诊断规则,结果表明了本文方法的有效性.

3) 本文方法对于提高航空发动机磨损故障诊断神经网络专家系统的知识获取能力及推理解释能力具有重要意义,同时对于利用神经网络从大量的航空发动机磨损故障样本中获取简洁的易于理解的诊断知识规则具有重要理论意义和参考价值.进一步收集发动机磨损故障样本,将本文方法与故障诊断的先验知识结合起来,并运用于实际的航空发动机磨损故障诊断,将是下一步继续深入研究的问题.

参考文献:

[1] 左洪福. 发动机磨损状态监测与故障诊断技术 [M]. 北京: 航空工业出版社, 1995.
ZUO Hongfu. Wear condition monitoring and fault diagnosis techniques for engine [M]. Beijing: Aviation Industry Press, 1995. (in Chinese)

[2] 陈果, 左洪福, 杨新. 基于神经网络的多种油样分析技术融合诊断 [J]. 摩擦学学报, 2003, 23(5):431-434.
CHEN Guo, ZUO Hongfu, YANG Xin. Neural-network-based fusion diagnosis using various oil analysis techniques [J]. Tribology, 2003, 23(5):431-434. (in Chinese).

[3] 陈果, 左洪福. 发动机磨损故障的集成神经网络融合诊断 [J]. 南京航空航天大学学报, 2004, 36(3):278-283.
CHEN Guo, ZUO Hongfu. Fusion diagnosis for engine wear fault based on integrated neural network[J]. Journal of Nanjing University of Aeronautics and Astronautics, 2004, 36(3):278-283. (in Chinese)

[4] 陈果. 基于神经网络和 D-S 证据理论的发动机磨损故障融合诊断[J]. 航空动力学报, 2005, 20(2):303-308.
CHEN Guo. Fusion diagnosis of engine wearing fault based on neural networks and D-S evidence theory [J]. Journal of Aerospace Power, 2005, 20(2):303-308. (in Chinese)

[5] Gallant S I. Connectional expert systems [J]. Communications of the ACM, 1988, 31(2):152-169.

[6] Saito K, Nakano R. Medical diagnostic expert system

- based on PDP model [C]// Proceedings of the IEEE International Conference on Neural Networks. New York: IEEE Press, 1988: 255-262.
- [7] Fu L M. Rule learning by searching on adapts nets [C]// Proceedings of the 9th National Conference on Artificial Intelligence. Anaheim, CA: AAAI Press, 1991: 590-595.
- [8] 周志华, 何佳洲, 尹旭日, 等. 一种基于统计的神经网络规则抽取方法[J]. 软件学报, 2001, 12(2): 263-269.
ZHOU Zhihua, HE Jiazhou, YIN Xuri, et al. A statistics-based approach for rule extracting from neural networks [J]. Journal of Software, 2001, 12(2): 263-269. (in Chinese)
- [9] Nguyen H S, Skowron A. Quantization of real values attributes, rough set and Boolean reasoning approaches [C]// Proceeding of the 2nd Joint Annual Conference on Information Science. Wrightsville Beach, NC: 1995: 34-37.
- [10] 陈果. 一种实现结构风险最小化思想的结构自适应神经网络模型[J]. 仪器仪表学报, 2007, 28(10): 1874-1879.
CHEN Guo. Structure self-adaptive neural network model realizing structural risk minimization principle[J]. Chinese Journal of Scientific Instrument, 2007, 28(10): 1874-1879. (in Chinese)
- [11] Kantardzic M. Data mining concepts, models, methods, and algorithms [M]. New York: IEEE Press, 2002.
- [12] Pawlak Z. Rough set [J]. International Journal of Information and Computer Science. 1982, 11(5): 341-356.
- [13] 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 Guoyin. Rough set theory and knowledge acquisition [M]. Xi'an: Xi'an Jiaotong University Press, 2001. (in Chinese)
- [14] 常犁云, 王国胤, 吴渝. 一种基于 Rough Set 理论的属性约简及规则提取方法[J]. 软件学报, 1999, 10(11): 1207-1211.
CHANG Liyun, WANG Guoyin, WU Yu. An attribute reduction and rule extraction based on rough set [J]. Journal of Software, 1999, 10(11): 1207-1211. (in Chinese)
- [15] 吴福保, 李奇, 宋文忠. 基于粗集理论知识表达系统的一种归纳学习方法[J]. 控制与决策, 1999, 14(3): 206-211.
WU Fubao, LI Qi, SONG Wenzhong. An induction learning method based on rough sets knowledge expression system [J]. Control and Decision, 1999, 14(3): 206-211. (in Chinese)
- [16] 文振华. 智能诊断专家系统知识获取方法研究及应用[D]. 南京: 南京航空航天大学, 2006: 64-65.
WEN Zhenhua. Research and application on knowledge acquisition of expert system for intelligent diagnosis [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2006: 64-65. (in Chinese)