

基于 AFPN 的汽车故障诊断研究

金永夫¹, 郝平^{1*}, 张华波¹, 袁华炜²

(1. 浙江工业大学 信息工程学院, 浙江 杭州 310014; 2. 绍兴文理学院 计算机学院, 浙江 绍兴 312000)

摘要:针对汽车故障诊断专家系统的知识具有动态性和不确定性的特点, 提出了一种基于自适应模糊 Petri 网 (AFPN) 的汽车故障诊断方法。该方法首先根据模糊产生式规则建立相应的模糊 Petri 网模型, 然后利用 BP 算法, 通过样本数据对模糊 Petri 网中的权值等进行反复的学习训练, 最后利用训练得到的参数和故障征兆发生概率对故障进行诊断。这种方法使知识库能动态更新, 并可以避免依靠人工经验设置带来的不确定性。诊断结果表明, 和传统故障树方法相比, 该方法具有很多优点。

关键词:自适应模糊 Petri 网; 故障诊断; 知识表示; 知识学习; 汽车

中图分类号: TP206⁺.3

文献标识码: B

文章编号: 1001-4551(2010)05-0090-05

Research on auto fault diagnosis based on AFPN

JIN Yong-fu¹, HAO Ping¹, ZHANG Hua-bo¹, YUN Hua-wei²

(1. College of Information Engineering, Zhejiang University of Technology, Hangzhou 310014, China;

2. Department of computer, Shaoxing University, Shaoxing 312000, China)

Abstract: Aiming that knowledge in the automobiles fault diagnosis expert system is dynamic and uncertain, a method based on the adaptive fuzzy Petri nets (AFPN) was proposed to solve the problem. In this method, at first a fuzzy Petri net was set up by the fuzzy production rule. Then the parameters of the fuzzy Petri net were trained by BP learning algorithm. At last, the fault origin can be found through the trained parameters and fault inferences. Using this method, the knowledge can be updated dynamically, and the uncertainty coming from people's setting can be avoided as well. The diagnosis result indicates that this method has many more merits than the fault tree diagnosis method.

Key words: adaptive fuzzy Petri nets (AFPN); fault diagnosis; knowledge representation; knowledge learning; automobiles

0 引言

汽车故障诊断专家系统是一个具有相关领域内大量专家知识的复杂智能程序系统, 它的知识具有模糊性和动态更新的特点。目前广泛应用于汽车故障诊断的方法有产生式规则推理算法和故障树分析法, 如文献[1-4]分别对它们进行了研究。产生式表示法具有自然性和模块性的特点, 但它对知识表达的结构不够清晰, 知识获取困难; 故障树分析法 (Fault Tree Analysis, FTA) 是一种由果到因的分析方法, 它具有模型结构清晰、知识获取简单等特点, 但故障树分析法对推理的过程具有一定盲目性, 一般需要采用优先搜索策略

遍历各个解, 推理速度慢, 且无法诊断并发性故障。

文献[5]提出的模糊 Petri 网模型不仅具有故障树分析法结构清晰的特点, 而且拥有产生式表示法的自然性, 更具有对并发性故障的诊断能力, 结合模糊集合理论, 使知识表示更符合人类的认知。文献[6-7]提出的自适应模糊 Petri 网 (AFPN) 是基于模糊产生式规则的动态知识库系统的良好建模工具, 它不仅具有一般模糊 Petri 网清晰的知识建模和推理能力, 而且结合神经网络的学习算法, 能够对描述模糊含义的参数进行自学习, 从而解决模糊系统的参数难以获取的问题。

本研究提出基于 AFPN 的汽车故障知识表示与推理方法, 首先根据汽车故障知识的模糊产生式规则表示

建立模糊 Petri 网模型,并利用 BP 算法实现对模糊参数的调整,最后用调整后的参数对汽车故障进行诊断。

1 自适应模糊 Petri 网的基本原理

1.1 自适应模糊 Petri 网

定义 1 AFPN 可定义成一个十一元组:
 $AFPN = (P, T, D, I, O, M, Th(t), W, \mu, \beta, \theta)$
式中 P —有限库所集,表示模糊命题, $P = \{p_1, p_2, \dots, p_n\}$; T —有限变迁集,表示规则的实现, $T = \{t_1, t_2, \dots, t_m\}$; D —命题的有限集合, $D = \{d_1, d_2, \dots, d_n\}$, $|P| = |D|$, $P \cap T \cap D = \emptyset$; $I: P \rightarrow T$ —输入函数,反映库所到变迁的映射关系; $O: T \rightarrow P$ —输出函数,反映变迁到库所的映射关系; $M: P \rightarrow [0, 1]$ —标识函数,给库所 $p_i \in P$ 分配一个标识 $M(p_i)$,为该库所对应模糊命题的真值,而 $M(p_i)$ 更可以跟自然语言进行对照,如表 1 所示; $Th(t) = \lambda: T \rightarrow [0, 1]$ —给每个变迁分配一个阈值; $W = \{\omega_1, \omega_2, \dots, \omega_r\}$ —弧对应的权值,其中 $0 \leq \omega_j \leq 1$, $\sum_{j=1}^r \omega_j = 1$; $\mu: T \rightarrow [0, 1]$ —给变迁赋予规则的确信度; $\beta: P \rightarrow D$ —反映库所节点与命题之间的一一对应关系; $\theta: P \rightarrow W$ —给每个库所赋予权值。

表 1 $M(p_i)$ 与自然语言对照表

$M(p_i)$	1.0 ~ 0.8	0.8 ~ 0.5	0.5 ~ 0.2	0.2 ~ 0.0
模糊定义	很可能	比较可能	较小可能	不可能

定义 2 若 $p_i \in I(t)$, $t \in T$, 则从库所 p_i 到变迁 t 之间有一条有向弧,是变迁 t 的输入弧。 p_i 是变迁 t 的输入库所,若 $p_j \in O(t)$, 则从变迁 t 到库所 p_j 之间有一条有向弧,是变迁 t 的输出弧, p_j 是变迁 t 的输出库所。

1.2 加权模糊产生式规则的 FPN 表示

汽车故障诊断的知识表示一般都以产生式规则表示,而考虑到规则的每个前提对结论的影响程度的不同,故用加权模糊产生式规则来表示知识。一般来说,加权模糊产生式规则是用来描述前提与结论命题之间的模糊关系。假设 R 为一模糊产生式规则集, $R = \{R_1, R_2, \dots, R_n\}$ 。那么第 i 条模糊产生式规则为:

$R_i: \text{If } d_j \text{ Then } d_k (\lambda_i, \omega_{ij}, CF = \mu_i)$


式中 d_j, d_k —包含模糊变量的前提与结论命题,每个命题取值范围在 0 ~ 1 之间; $\omega_{ij}, \lambda_i, \mu_i$ —对应规则的权重、阈值和规则可信度。

这里只要令 $P \rightarrow D$, 并将对应的规则模糊系数与 Petri 网模糊系数一一对应,就能将加权模糊产生式规则转化为模糊 Petri 网模型,从而利用模糊 Petri 网模型对故障进行分析。

假设有如下产生式规则:

IF“汽车启动时发动机前部发出‘吱吱’的响声” THEN“电动机皮带松弛”($\omega = 1, \lambda = 0.2, \mu = 0.9$)

根据以上规则,令 $P \rightarrow D$, 可得到 AFPN 模型,如图 1 所示。



这里假设了“汽车启动时发动机前部发出‘吱吱’的尖叫声”的可信度为 0.8,其对结论的影响权重为 1,整条规则的阈值为 0.2,可信度为 0.9。

1.3 模糊 Petri 网的推理算法

定义 3 在模糊 Petri 网模型中, $\forall t \in T$, 若 $\forall p_i \in I(t)$, $\sum_{i=1}^m M(p_i) \times \omega_i \geq Th(t)$, 则变迁 t 是使能的, $i = 1, 2, \dots, n$ 。

在模糊 Petri 网模型推理过程中,变迁使能触发后,其前提条件部分所代表的命题的置信度并不消失,而在输出库所 p 传递得到一个置信度为 $M(p)$ 的新 Token, $M(p)$ 的计算公式为:

$$M(p) = \begin{cases} f(t) \sum_{i=1}^m M(p_i) \times \omega_i & \sum_{i=1}^m M(p_i) \times \omega_i \geq Th(t) \\ 0 & \sum_{i=1}^m M(p_i) \times \omega_i \leq Th(t) \end{cases} \quad (1)$$

输出库所 p 为多个变迁的后继库所,当这些变迁触发后,库所 p 中得到的标识值是传送来的值中最大的, $M(p)$ 的计算公式为:

$$M(p) = \max \begin{pmatrix} f(t_1) \times \sum_{j=1} M(p_{1j}) \times \omega_{1j}, \\ f(t_2) \times \sum_{j=1} M(p_{2j}) \times \omega_{2j}, \\ \dots, \\ f(t_n) \times \sum_{j=1} M(p_{nj}) \times \omega_{nj} \end{pmatrix} \quad (2)$$

$p_{ij} \in I(t_i), i = 1, 2, \dots, n$

在具体实现推理算法的时候,可以参考文献[8]提出的方法,把模糊 Petri 网模型推理算法转化为矩阵形式,将推理过程转化为矩阵运算。这样更便于计算机的处理,且具有简单、高效的特点。

2 自适应模糊 Petri 网的学习算法

一般来说,FPN 中规则的参数(如 ω, λ, μ)都是靠专家经验得到,有很多的局限性,而 AFPN 具有神经网络的某些特性,因此可以应用神经网络的学习算法

对模糊参数进行训练,自适应地调整 AFPN 中的权值等参数,本研究采用 BP 算法来调整参数。

2.1 模糊推理中连续函数的建立

由于 AFPN 模型是以 BP 算法来实现参数的自适应,而 BP 算法主要思想是梯度下降法,必须对函数作求导运算,引入 Sigmoid 连续函数:

$$\varphi(x) = \frac{1}{1 + e^{-b(x-\lambda)}} \quad (3)$$

其中, $x = \sum_{i=1}^m M(p_i) \times \omega_i$; λ 为阈值, b 足够大,当 $x > \lambda$ 时,则 $\varphi(x) \approx 1$; 当 $x < \lambda$ 时, $\varphi(x) \approx 0$ 。将式(1)转化为连续函数 $G(x)$, 得:

$$G(x) = M(p) = \varphi(x) \cdot x \cdot \mu \quad (4)$$

当输出库所 p 为多个变迁的后继库所时,库所 p 中得到标识值传送来的最大值的连续函数为:

$$M(p) = \max(y_1, y_2) \approx \frac{y_1}{(1 + e^{-b(y_1 - y_2)})} + \frac{y_2}{(1 + e^{-b(y_2 - y_1)})} \quad (5)$$

2.2 AFPN 中的 BP 学习算法

BP 算法是一种有教师的训练算法,它在给定目标的情况下,以实际输出与目标值之差的平方和为目标函数,以调节权值使目标函数达到最小值为最终目的,本研究以误差函数 E 作为目标函数。

在本研究中,笔者设 AFPN 模型有 n 层,有 b 个终止库所 $p_j, j = 1, 2, \dots, b$, 用 r 批样本数据进行训练,则:

$$E = \frac{1}{2} \sum_{i=1}^r \sum_{j=1}^b (M_i(p_j) - M_i^*(p_j))^2 \quad (6)$$

式中 $M_i(p_j), M_i^*(p_j)$ —终止库所 p_j 的第 i 批样本数据的实际标记值和期望标记值。

若对 r 个学习实例的任一实例 K 的 b 个终止库所都分别满足实例 K 的 b 个期望输出,即 $E \leq \varepsilon$, 则学习过程结束, ε 为指定的允许误差;否则由误差反向传播过程修改参数。

设 ψ 为待学习参数, ψ 表示权值 ω , 阈值 λ 和可信度 μ ; $t_i^{(n)}$ 是 AFPN 模型第 n 层的一个变迁, m 表示该变迁的输入库所数,若 $p_j^{(n)} \in O(t_i^{(n)})$, 则显然 $p_j^{(n)}$ 是终止库所,用 BP 算法计算一阶梯度得:

$$\frac{dE}{d\psi_{ix}^{(n)}} = \frac{dE}{dM^{(n)}(p_j)} \frac{dM^{(n)}(p_j)}{d\psi_{ix}^{(n)}} = \delta_i^{(n)} \tau_{ix}^{(n)} \quad (7)$$

$$\text{其中, } \delta_i^{(n)} = \frac{dE}{dM^{(n)}(p_j)}; \tau_{ix}^{(n)} = \frac{dM^{(n)}(p_j)}{d\psi_{ix}^{(n)}}; x = 1,$$

2, $\dots, m+2$ 。

若变迁 $t_i^{(n-1)}$ 是 AFPN 模型在第 $n-1$ 层的一个变迁,设 $p_j^{(n-1)} \in O(t_i^{(n-1)})$, 如果 $p_j^{(n-1)}$ 为终止库所,则一

阶梯度的计算方法与第 n 层的计算方法相同;如果 $p_j^{(n-1)}$ 为非终止库所,则 $\exists t_i^{(n)} \in T_n$, 且 $p_j^{(n-1)} \in I(t_i^{(n)})$, 同时 $\exists p_l^{(n)} \in O(t_i^{(n)}), p_l^{(n)}$ 为终止库所,采用误差反向传播,第 $n-1$ 层变迁的一阶梯度计算如下:

$$\frac{dE}{d\psi_{ix}^{(n-1)}} = \frac{dE}{dM^{(n)}(p_l)} \frac{dM^{(n)}(p_l)}{dM^{(n-1)}(p_j)} \frac{dM^{(n-1)}(p_j)}{d\psi_{ix}^{(n-1)}} = \delta_i^{(n-1)} \tau_{ix}^{(n-1)} \quad (8)$$

$$\text{其中, } \delta_i^{(n-1)} = \delta_i^{(n)} \frac{dM^{(n)}(p_l)}{dM^{(n-1)}(p_j)}; \tau_{ix}^{(n-1)} = \frac{dM^{(n-1)}(p_j)}{d\psi_{ix}^{(n-1)}};$$

$x = 1, 2, \dots, m+2$ 。

依次对 $n-2, n-3, \dots, 1$ 层计算出 $dE/d\psi_{ix}^{(q)}$, 则各参数根据下式进行调整:

$$\begin{bmatrix} A_1^{(q)}(k+1) \\ A_2^{(q)}(k+1) \\ \vdots \\ A_s^{(q)}(k+1) \end{bmatrix} = \begin{bmatrix} A_1^{(q)}(k) \\ A_2^{(q)}(k) \\ \vdots \\ A_s^{(q)}(k) \end{bmatrix} - \eta \begin{bmatrix} \Delta_1^{(q)} & 0 & \cdots & 0 \\ 0 & \Delta_2^{(q)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \Delta_s^{(q)} \end{bmatrix} \begin{bmatrix} B_1^{(q)} \\ B_2^{(q)} \\ \vdots \\ B_s^{(q)} \end{bmatrix} \quad (9)$$

式中 η —学习速率; k —学习的次数; $A_s^{(q)}$ — q 层第 s 个变迁的模糊参数向量, $A_s^{(q)} = [\omega_{s1}^{(q)} \omega_{s2}^{(q)} \cdots \omega_{sx}^{(q)} \mu_s^{(q)} \lambda_s^{(q)}]^T$; $\Delta_s^{(q)}$ — $\delta_s^{(q)}$ 与单位对角矩阵的乘积; $B_s^{(q)} = [\tau_{s\omega 1}^{(q)} \tau_{s\omega 2}^{(q)} \cdots \tau_{s\omega x}^{(q)} \tau_{s\mu}^{(q)} \tau_{s\lambda}^{(q)}]^T$; $q = n, n-1, \dots, 1$; $s = 1, 2, \dots$ 。

式(9)可简写为:

$$A^{(q)}(k+1) = A^{(q)}(k) - \eta F^{(q)} B^{(q)},$$

$$F^{(q)} = \begin{bmatrix} \Delta_1^{(q)} & 0 & \cdots & 0 \\ 0 & \Delta_2^{(q)} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \Delta_s^{(q)} \end{bmatrix}$$

2.3 AFPN 的训练步骤

自适应模糊 Petri 网的训练步骤如下:

(1) 对 AFPN 模型模型进行分层^[9], 并对各类模糊参数赋初值。

(2) 对 r 批样本数据进行推理计算, 得到各库所标识值。

(3) 计算误差函数 E , 如 $E < \varepsilon$, 则学习结束, 否则执行下一步。

(4) 运用 BP 学习算法, 对 r 组样本依次进行学习, 经过 r 次的参数学习调整, 将调整后的参数带到步骤(2)继续执行。

3 AFPN 模型学习及诊断实例

3.1 AFPN 模型的建立

本研究以汽车无法正常启动故障作为实例, 取其

中一部分规则进行讨论分析,具体规则如下:

R_1 :If 仪表盘亮(d_1)and 起动机转动(d_2)and 点火火花不正常(d_3)and 油箱中油量正常(d_4)Then 点火系统故障(d_5);

R_2 :If 点火系统故障(d_5)and 发动机运转不稳(d_6)and 火花塞正常(d_7)Then 点火线路故障(d_8);

R_3 :If 点火系统故障(d_5)and 火花塞不正常(d_9)Then 火花塞故障(d_{10})。

根据以上规则,令 $P \rightarrow D$,可得到 AFPN 模型,如图 2 所示。




图2 发动机无法启动 AFPN 模型

3.2 AFPN 模型参数学习与测试

本研究针对权值和规则置信度进行学习,根据以上发动机无法启动的故障模型,用 10 批样本数据进行训练,初始库所集合 $PM = \{p_1, p_2, p_3, p_4, p_6, p_7, p_9\}$,终止库所集合 $PO = \{p_8, p_{10}\}$ 。其中, $b = 10\ 000$, $\eta = 0.01$,假设所有的阈值 $\lambda = 0.0$,初始参数 $\omega_{11}^{(1)} = 0.25, \omega_{12}^{(1)} = 0.25, \omega_{13}^{(1)} = 0.25, \omega_{14}^{(1)} = 0.25, \omega_{11}^{(2)} = 0.65, \omega_{12}^{(2)} = 0.35, \omega_{21}^{(2)} = 0.33, \omega_{22}^{(2)} = 0.34, \omega_{23}^{(2)} = 0.33, \mu_1^{(1)} = 0.9, \mu_1^{(2)} = 0.88, \mu_2^{(2)} = 0.98$ 。

在本研究中,对 10 组样本进行 600 次左右的训练,权重系数趋于稳定(如图 3 所示)。图中 $\omega_{21}^*, \omega_{22}^*, \omega_{23}^*$ 都为期望权重。




图3 权重 w_2 的参数训练过程

经过 600 次的训练后,得到各参数的值为: $\omega_{11}^{(1)} = 0.184\ 1, \omega_{12}^{(1)} = 0.179\ 7, \omega_{13}^{(1)} = 0.510\ 4, \omega_{14}^{(1)} = 0.125\ 8, \omega_{11}^{(2)} = 0.892, \omega_{12}^{(2)} = 0.108, \omega_{21}^{(2)} = 0.107\ 8, \omega_{22}^{(2)} = 0.700\ 3, \omega_{23}^{(2)} = 0.191\ 9, \mu_1^{(1)} = 0.741\ 9, \mu_1^{(2)} = 0.925, \mu_2^{(2)} = 0.898$ 。

用经过训练的参数对下面的汽车无法启动故障的输入进行推理,由 $PM = \{1, 0.7, 0.6, 0.8, 0.6, 0.2, 0.95\}$,得:

$\{p_8, p_{10}\} = \{0.279, 0.837\}$

由此可知,该汽车无法启动故障“很可能”是由“火花塞故障”引起的。

4 AFPN 与传统 FTA 比较

基于产生式规则表达的最常用故障诊断方法是传统的 FTA 方法。AFPN 与传统 FTA 相比具有很多优点,以图 2 故障为例,其故障树如图 4 所示。




图4 发动机点火系故障树

根据对图 2 和图 4 的分析,得出的 AFPN 与传统 FTA 之间对比所体现的优点如表 2 所示。

表2 AFPN 与 FTA 对照表	
AFPN 特点	FTA 特点
能表示多个故障征兆与原因间多对多关系	对复杂系统知识表示过于庞大,且不易表示故障树之间关系
可以用权值 ω 直观地看出条件对结论的影响程度	只能通过计算重要度得到条件对结论的重要度
可以对表示模糊概念的参数进行自学习,参数更客观准确	对描述模糊概念的参数没有学习功能,只能由人为确定
可以诊断并发故障	只能同时诊断单个故障

5 结束语

Petri 网是具有严格数学定义的图形建模工具,具有很强的知识表达和推理能力。针对汽车故障诊断的特点,结合模糊逻辑、人工神经网络和 Petri 网模型,本研究提出了能够自适应地调整模糊参数的自适应模糊 Petri 网模型。该模型的知识来源于专家经验,又对专家经验进行学习,使诊断知识可以动态实时调整,增强了系统对外界环境的适应能力,提高了故障诊断系统的精度。但本算法的一个缺陷是自学习收敛速度比较慢,因此可以引入对 BP 算法加速收敛的一些方法,如引入动量项、变尺度法、变步长法等都可以加速收敛。

(下转第 101 页)

表 1 设计结果比较

设计方法	FLASH 空间/KB	RAM 空间/KB	启动 速度/ms	代码 重用率/(%)
CCS 组件设计	引擎	63.95		
	界面	7.55	1.72	1.68
	共计	71.50		90
传统嵌入式设计	75.63	1.85	1.63	30

从表 1 中可以看出,采用 CCS 组件设计方案后 Flash 和 RAM 空间使用有明显的下降。虽然在界面数据中增加了索引表,但传统嵌入式设计方法必须要花费更多的空间用于描述界面之间的图形组件之间的关系。在界面数据中,索引结构表只使用了 208 个字节,占整个界面数据的 0.3%。由于 CCS 组件设计的引擎系统除了在上电时初始化硬件外,还需读 Flash 初始化一级索引表在内的大量数据,启动速度比普通嵌入式设计方法设计的系统要慢。但在人机界面系统中,上电启动时需花大量的时间进行 LCD 初始化和 LCD 清屏,因此启动速度只慢了 50 μs(该速度是完全可以接受的)。

4 结束语

针对嵌入式裸机的图形界面系统开发效率低等问题,本研究提出了一种新型嵌入式开发模式 CCS 模型,在上电前通过该模型加载所需组件,实现系统的可重构,实现资源的灵活配置。CCS 组件设计方法可以

广泛适用于基于裸机平台的嵌入式系统的开发中,尤其是嵌入式图形设计,可以提高系统的开发效率、减少内存消耗。为嵌入式系统开发提供了一种切实可行的方法。

参考文献(References):

[1] XU Dong, TENG Qi-ming, CHEN Xiang-qun. Supports for Components Loading and Binding at Boot-time for Component-based Embedded Operating Systems[C]. Second International Conference on Embedded Software and Systems 2005. Xi'an: [s. n.], 2005.

[2] LINDGREN P, ERIKSSON J, AITTAMAA S, et al. Tiny-Timber, Reactive Objects in C for Real-Time Embedded Systems[C]//The IEEE Computer Society 2008. Munich: [s. n.], 2008:1382 – 1385.

[3] BAYNES K, COLLINS C, FITTERMAN E, et al. The performance and energy consumption of embedded real-time operating systems[J]. **IEEE Transactions on Computers**, 2003, 52(11):1454 – 1469.

[4] COULSON G, BLAIR G, GRACE P, et al. A generic component model for building systems software [J]. **ACM Transactions on Computer Systems**, 2008, 26(1):1 – 42.

[5] 廖 渊,唐 磊,李明树. 一种基于 Qos 的服务构建组合方法[J]. 计算机学报, 2005, 28(4):627 – 634.

[6] 章琛曦,陈耀武. 基于计算机网络的嵌入式系统监控软件远程动态加载方法[J]. 仪器仪表学报, 2001, 22(4):340 – 341.

[7] 宋 荣. 基于 Qt/Embedded 的嵌入式系统 GUI 开发[J]. 机电工程, 2009, 26(4):90 – 92, 109.

[8] 于孝辉,陈秋艳,李国义. 嵌入式 Linux 下 MiniGUI 的移植及软件开发[J]. 辽宁工程学院学报, 2006, 26(2):90 – 93.

[编辑:李 辉]

(上接第 93 页)

参考文献(References):

[1] 谢振伟. 基于规则的特装车辆故障诊断专家系统的研究[D]. 哈尔滨:哈尔滨工程大学计算机科学与技术学院, 2006.

[2] 陈朝阳,张代胜,任佩红,等. 基于故障树分析法的汽车故障诊断专家系统[J]. 农业机械学报, 2003, 34(5):130 – 133.

[3] 纪常伟. 基于故障树的汽车故障诊断系统开发[J]. 汽车与动力技术, 2003(1):52 – 57.

[4] 赵艳萍,贡文伟. 模糊故障树分析及其应用研究[J]. 中国安全科学学报. 2001, 11(6):31 – 35.

[5] CHEN S M, KE J S, CHANG J F. Knowledge representation using fuzzy petri nets[J]. **IEEE Trans. Knowledge**

and Data Engineering, 1990(3):311 – 319.

[6] LI Xiao-ou, YU Wen, LARA-ROSANO F. Dynamic knowledge inference and learning under adaptive fuzzy Petri net framework[J]. **IEEE Transactions on Systems, Man and Cybernetic-Part C: Applications and Reviews**, 2000, 30(4):442 – 449.

[7] LI Xiao-ou, LARA-ROSANO F. Adaptive fuzzy Petri nets for dynamic knowledge representation and inference [J]. **Expert Systems with Applications**, 2000, 19(3):235 – 241.

[8] 申宇皓,孟晨,傅振华,等. 加权模糊 Petri 网的推理算法研究[J]. 军械工程学院学报, 2008, 20(3):59 – 62.

[9] 鲍培明. 基于 BP 网络的模糊 Petri 网的学习能力[J]. 计算机学报, 2004, 27(5):695 – 702.

[编辑:李 辉]