

文章编号: 1001-0920(2005)03-0341-04

基于NNFPN模型的电梯故障诊断方法的研究

宗群, 马宏波, 王中海

(天津大学电气与自动化工程学院, 天津 300072)

摘要: 提出一种基于神经网络的模糊Petri网模型(NNFPN), 并将该模型应用于电梯故障诊断系统。阐述了该模型的定义、模糊产生式规则的NNFPN表示、NNFPN的触发规则以及NNFPN的训练学习算法。分析了如何建立基于NNFPN的电梯故障诊断模型, 提出针对不同工作状态利用不同的NNFPN电梯故障模型进行诊断, 可使诊断结果更加准确。

关键词: 模糊Petri网; 神经网络; NNFPN; 故障诊断; 电梯

中图分类号: TP27 **文献标识码:** A

On elevator fault diagnosis method based on NNFPN model

ZONG Qun, MA Hong-bo, WANG Zhong-hai

(School of Electrical Engineering and Automation, Tianjin University, Tianjin 300072, China. Correspondent: MA Hong-bo, Email: mahongbo317@eyou.com)

Abstract: A kind of fuzzy petri net model used in fault diagnosis of the elevator system based on neural network is proposed. The definition of this model, the NNFPN presentation of the fuzzy production rule, the burst rule of NNFPN, and the learning algorithm of NNFPN are addressed. The way to establish the NNFPN model of the elevator fault diagnosis system is analyzed. It is pointed out that, to elevators in different condition, the different NNFPN model should be used to do fault diagnosis. Thus the reasoning result could be more accurate and even match actual circumstance.

Key words: fuzzy Petri net; neural network; NNFPN; fault diagnosis; elevator

1 引言

随着城市中高层建筑物的增多, 电梯得到越来越广泛的应用。电梯设备已成为重要的运输设备之一, 这就要求电梯具有很高的可靠性。现代电梯的可靠性已经大大提高, 但电梯运行中关人、夹人、蹲底、冲顶、溜梯等事故时有发生。因此, 需要依靠完善的维修保养体系和先进的故障诊断手段来提高电梯运行的可靠性。

许多学者利用人工智能的方法对电梯故障进行诊断, 但是单一的智能诊断方法存在这样那样的缺陷。将多种不同的智能技术结合起来形成混合诊断方法, 是智能故障诊断研究的一个发展方向。

2 NNFPN模型的提出

在故障诊断领域, 许多学者对模糊Petri网(FPN)和神经网络(ANN)作了广泛研究。FPN能解释系统的结构和动态行为的重要信息, 图形化地表达系统的模型, 逻辑意义明确。基于FPN的故障诊断方法可将知识表示与诊断推理融为一体, 完成描述性知识和过程性诊断推理, 通过简单的矩阵计算即可快速获得诊断结果, 但FPN缺乏良好的调整学习机制, 不能处理实际系统的潜在变化。ANN作为一种自适应的模式识别技术, 并不需要预先给出关于模式的先验知识和判别函数, 通过自身的学习机制便可自动形成所要求的决策区域, 并且可以连续学习。

综上所述, 可将ANN与FPN相结合, 用ANN

收稿日期: 2004-06-10; 修回日期: 2004-09-13

基金项目: 天津市重点科技攻关项目(013107211)。

作者简介: 宗群(1961—), 男, 天津人, 教授, 博士生导师, 从事随机离散事件、故障诊断等研究; 马宏波(1982—), 男, 安徽合肥人, 硕士生, 从事故障诊断方法的研究。

去弥补FPN的学习功能 20世纪90年代以来,国内外一些学者在这方面作了许多研究,提出一些新的模型和概念^[1-7]. 本文在参考已有研究成果的基础上,将FPN的模糊推理功能与ANN的学习功能结合起来,提出一种基于神经网络的模糊Petri网模型(NNFPN),并将其应用于电梯故障诊断系统

3 NNFPN模型的基本原理

3.1 定义与函数

定义1 NNFPN是一个9元组

$$NNFPN = \{P, T, F, W, \alpha, \lambda, \mu, Y, M_0\} \quad (1)$$

其中: $P = \{p_1, p_2, \dots, p_m\}$ 是库所的有穷集合, $T = \{t_1, t_2, \dots, t_n\}$ 是变迁的有穷集合, F 是连接库所和变迁的有限个弧的集合, $W: F \rightarrow [0, 1]$ 为弧对应的权值, $\alpha: P \rightarrow [0, 1]$ 为库所对应命题的置信度, $\lambda: T \rightarrow [0, 1]$ 为每个变迁分配一个阈值, $\mu: T \rightarrow [0, 1]$ 为变迁所对应规则的置信度, $Y = \{y_1, y_2, \dots, y_m\}$ 为每个变迁分配一个输出函数, $M_0 = \{\alpha_0, \alpha_1, \dots, \alpha_m\}$ 为网络的初始标识

变迁对应的输出函数 Y 可选用神经网络中常用的 Sigmoid 函数

$$\mathcal{Q}(x) = \frac{1}{1 + \exp(-c(x - \lambda))} \quad (2)$$

其中 c 是控制曲线斜率的常数 当 c 足够大时, 如果 $x > \lambda$, 则 $\exp(-c(x - \lambda)) \rightarrow 0, \mathcal{Q}(x) \rightarrow 1$; 如果 $x < \lambda$, 则 $\exp(-c(x - \lambda)) \rightarrow \infty, \mathcal{Q}(x) \rightarrow 0$

3.2 模糊产生式规则的NNFPN表示

这里以结合式模糊产生式规则为例, 其规则如下:

If p_1 and p_2 and ... and p_n ,

Then $P, c_f = \mu, T_h(t) = \lambda, W_l(p_i, t) = \omega_i,$

$$W_o(t, p) = \mu \quad (i = 1, 2, \dots, n). \quad (3)$$

其中: p_1, p_2, \dots, p_n 为输入库所, P 为输出库所, c_f 表示变迁 t 所对应规则的置信度, T_h 表示每个变迁对应的阈值, W_l 表示连接输入库所到变迁的弧权值, W_o 表示连接变迁到输出库所的弧权值

相应的NNFPN模型如图1所示 其中黑点表示托肯, 托肯值(即库所代表的命题的置信度)分别为 $\alpha(p_1), \alpha(p_2), \dots, \alpha(p_n)$.




图1 结合式模糊产生式规则

3.3 NNFPN的触发规则




图2 NNFPN中变迁的触发

对于图2所示的变迁 t , 有如下触发规则:

如果 $\omega\alpha(p_i) < \lambda$ 则 t 不能触发;

如果 $\omega\alpha(p_i) \geq \lambda$ 则 t 被触发

变迁触发后, 其前提部分所代表命题的置信度并不消失, 而在输出库所 P 中增加一个置信度为 $\alpha(P)$ 的新托肯 $\alpha(P)$ 的计算公式为

$$\alpha(P) = \begin{cases} \alpha(p_i)\omega_i, & \alpha(p_i)\omega_i \geq \lambda \\ 0, & \alpha(p_i)\omega_i < \lambda \end{cases} \quad (4)$$

4 NNFPN的学习

NNFPN 具有神经网络的某些特性, 因此可先用神经网络的学习算法进行训练学习, 再调整网络结构中的权值, 从而获取知识 当网络结构复杂时, NNFPN 可进一步扩展, 而不仅仅由单层神经元组成 本文的学习算法采用神经网络中的BP算法

下面以结合式模糊产生式规则为例来说明 NNFPN 中的学习过程 将图2所示的NNFPN模型转化为神经元模型, 如图3所示




图3 NNFPN的神经网络转化

由图3可知

$$\alpha(p_3) = \mathcal{Q}(x) \quad (x + \lambda)\mu = f(x),$$

$$x = \alpha(p_1)\omega_1 + \alpha(p_2)\omega_2 - \lambda,$$

$$\mathcal{Q}(x) = \frac{1}{1 + e^{-cx}}$$

由专家经验得出的样本数据可用于训练网络和调整权值 当给出 $\alpha(p_1)$ 和 $\alpha(p_2)$ 时, 可得到专家给出的期望输出 $\alpha(p_3)$. 于是输出误差为 $e = \alpha(p_3) - \alpha(p_3)$. 按如下策略更新权值 ω 和 ω :

$$\begin{bmatrix} \omega(n+1) \\ \omega(n+1) \end{bmatrix} =$$

$$\begin{bmatrix} \omega(n) \\ \omega_2(n) \end{bmatrix} + \eta^\circ(x) e(n) \begin{bmatrix} \alpha(p_1(n)) \\ \alpha(p_2(n)) \end{bmatrix}, \quad n = 1, 2, \dots \quad (5)$$

其中

$$f^\circ(x) = \frac{d}{dx} [\mathcal{Q}(x)(x + \lambda)\mu] = \frac{\mu}{1 + e^{-cx}} + \frac{\mu c(x + \lambda)e^{-cx}}{1 + e^{-cx}},$$

$$x = \alpha(p_1(n))\omega(n) + \alpha(p_2(n))\omega_2(n) - \lambda,$$

$$e(n) = \alpha(p_3(n)) - \alpha(p_3(n)),$$

η 为学习率, n 为计算次数

可以看出, 式(5) 是常用的 BP 算法的一个特例, 它对应于网络中只有一层的情况 BP 算法的实质是梯度下降法, 在实际应用中存在两个重要问题: 收敛速度慢, 目标函数存在局部极小值 因此需要对式(5) 进行改进

4.1 加入动量项

当神经网络进行训练学习时, 学习率 η 的选择是很重要的, η 大收敛速度快, 但可能不稳定而引起振荡; η 小虽然可避免不稳定, 但是收敛速度慢 解决这一问题的最简便方法是加“动量项”; 如下式所示:

$$\begin{bmatrix} \omega(n+1) \\ \omega_2(n+1) \end{bmatrix} = \begin{bmatrix} \omega(n) \\ \omega_2(n) \end{bmatrix} + \eta^\circ(x) e(n) \begin{bmatrix} \alpha(p_1(n)) \\ \alpha(p_2(n)) \end{bmatrix} + \alpha \begin{bmatrix} \omega(n) \\ \omega_2(n) \end{bmatrix}, \quad n = 1, 2, \dots \quad (6)$$

其中第 3 项即为动量项, 且 $0 < \alpha < 1$ 为避免振荡和加快收敛速度, 可选取如下规则:

$$\alpha = \begin{cases} 0, & e(n) < 0; \\ \alpha, & e(n) > 0 \end{cases} \quad (7)$$

4.2 修正学习率

为增强学习过程的鲁棒性, 减少个别受扰点误差大的影响, 将学习率修改为 $\eta(n) = \frac{\eta_0}{1 + e(n)}$, 式中 η_0 为初始学习率 式(5) 最后修改为

$$\begin{bmatrix} \omega(n+1) \\ \omega_2(n+1) \end{bmatrix} = \begin{bmatrix} \omega(n) \\ \omega_2(n) \end{bmatrix} + \frac{\eta_0}{1 + e(n)} f^\circ(x) e(n) \begin{bmatrix} \alpha(p_1(n)) \\ \alpha(p_2(n)) \end{bmatrix} + \alpha \begin{bmatrix} \omega(n) \\ \omega_2(n) \end{bmatrix}, \quad n = 1, 2, \dots \quad (8)$$

5 NNFPN 模型诊断实例

5.1 NNFPN 模型的建立

电梯在不同工作时期和不同负载状态下产生故

障的原因是不同的, 要给出固定的故障诊断规则可信度是不现实的 应对处于不同工作状态下的 NNFPN 电梯故障模型赋予不同的参数, 可用 3 组不同时期的电梯故障样本来训练网络, 调整权值和置信度, 针对每种故障分别建立不同的模型 当故障发生时, 对处于不同工作状态下的电梯分别利用相应的故障诊断模型进行诊断

首先建立基于 NNFPN 的电梯故障诊断模型, 用 NNFPN 模型作为电梯故障诊断的知识表示方法和推理策略; 然后在获取大量电梯专家经验知识的基础上, 将这些故障诊断专家知识用模糊产生式规则表示, 并转化为电梯故障诊断的 NNFPN 模型 对于 NNFPN 中的权值不确定部分, 可用不同的故障诊断样本对网络进行训练学习, 调整权值 训练学习好的 NNFPN 网络能保存大量的专家经验知识

限于篇幅, 仅以门刀与厅门滚轮脱挂的 NNFPN 模型为例^[8,9], 其 NNFPN 模型如图 4 所示 图中库所表示命题的含义如表 1 所示




图 4 门刀与厅门滚轮脱挂的 NNFPN 模型

表 1 门故障中各库所表示的命题含义

库所	库所表示的命题含义
p_1	到站平层开门时门刀与厅门滚轮脱挂
p_2	轿厢负载不均匀
p_3	厅门滚轮磨损严重
p_4	门刀与厅门滚轮啮合深度太浅
p_5	门刀与厅门滚轮不能啮合
p_6	门刀与厅门滚轮间隙未调整好
p_7	轿厢导轨平行度超差严重
p_8	轿厢压板螺丝松动严重

5.2 基于 NNFPN 模型的电梯故障诊断推理

NNFPN 的故障诊断推理就是 NNFPN 网络的计算过程 推理通过权值数据、规则置信度数据和输入数据的运算来完成, 即由符号运算转变为数值运算 推理的具体步骤如下:

- 1) 根据不同状态选择相应的 NNFPN 电梯故障模型;
- 2) 针对不同的电梯故障建立相应的故障征兆库所集;
- 3) 输入征兆库所集的置信度;

4) 根据NNFPN 触发规则找出当前的使能变迁;
 5) 计算由触发变迁产生的新的置信度;
 6) 重复步骤4), 直到当前的使能变迁为空集
 计算完毕, 将得到对应故障原因库所的置信度
 以到站平层开门时门刀与厅门滚轮脱挂的NNFPN 模型为例, 设经过训练后网络中各参数值如表2所示, 各变迁的阈值均为0.5 当输入 $\alpha(p_1) = 0.92$, $\alpha(p_2) = 0.60$ 时, 不同状态下的网络输出如表3所示

表2 门刀与厅门滚轮脱挂故障模型中各参数值

参数	磨合运行期	稳定运行期	磨损运行期
ω_1	1.00	1.00	1.00
ω_2	1.00	1.00	1.00
ω_3	0.25	0.30	0.20
ω_4	1.00	1.00	1.00
ω_5	1.00	1.00	1.00
ω_6	1.00	1.00	1.00
ω_7	0.75	0.70	0.80
μ_1	0.30	0.50	0.85
μ_2	0.95	0.81	0.74
μ_3	0.60	0.85	0.80
μ_4	0.82	0.60	0.55
μ_5	0.34	0.53	0.88
μ_6	0.71	0.95	0.82

表3 门刀与厅门滚轮脱挂故障模型的输出

参数	磨合运行期	稳定运行期	磨损运行期
$\alpha(p_3)$	0.27	0.45	0.77
$\alpha(p_6)$	0.70	0.44	0.37
$\alpha(p_7)$	0.29	0.39	0.59
$\alpha(p_8)$	0.33	0.56	0.43

从表3可以看出, 对于相同的输入, 网络在不同状态下的输出是不同的 同样是门刀与厅门滚轮脱挂故障, 如果电梯在磨合运行期, 那么可能是门刀与厅门滚轮间隙未调整好; 如果在稳定运行期, 那么可能是轿厢压板螺丝松动严重引起的; 如果在磨损运行期, 那么可能是厅门滚轮磨损严重造成的 对于不同的工作状态, 电梯故障模型要用不同的模型参数去计算推理, 才能使故障诊断的结果更加符合实际情况

6 结 论

本文提出一种基于神经网络的模糊Petri网模

型(NNFPN), 该模型综合了神经网络和模糊Petri网的优点, 用于故障诊断可使整个诊断系统不再是一个“黑箱”. NNFPN 具备基于知识的故障诊断专家系统的透明特性, 推理过程清晰可见, 意义明确 由于具有神经网络的学习能力, 该模型不再是固定不变的, 可以不断地学习新的专家经验知识 文中给出了NNFPN 的训练学习算法, 分析了如何建立基于NNFPN 的电梯故障诊断模型 针对不同工作状态利用不同的NNFPN 故障模型进行诊断, 可使诊断结果更加准确

参考文献(References)

- [1] Tsuji K, Matsumoto T. Extended Petri net models for neural networks and fuzzy inference engines—their net structural properties [A]. *IEEE Int Symp on Circuits and Systems* [C]. New Orleans, 1990, 4: 2670-2673
- [2] Kadjinicolaou M G, Abdelrazik M B E, Musgrave G. Structured analysis for neural networks using Petri nets [A]. *Proc of the 33rd Midwest Symp on Circuits and Systems* [C]. Calgary, 1990, 2: 770-773
- [3] Ahson S I. Petri net models of fuzzy neural networks [J]. *Systems, Man and Cybernetics*, 1995, 25(6): 926-932
- [4] Hanna M M, Buck A, Smith R. Fuzzy Petri nets with neural networks to model products quality from a CNC-milling machining center [J]. *Systems, Man and Cybernetics — Part A*, 1996, 26(5): 638-645
- [5] Tsang E C C, Yeung D S, Lee J W T. Learning capability in fuzzy Petri nets [A]. *IEEE SM C 99 Conf Proc* [C]. Tokyo, 1999, 3: 355-360
- [6] Li X O, Yu W, Lara Rosano F. Dynamic knowledge inference and learning under adaptive fuzzy Petri net framework [J]. *Systems, Man and Cybernetics — Part C*, 2000, 30(4): 442-450
- [7] Tracy D P, Jones I R. Synthesis of intelligent switching systems using neural Petri nets [A]. *IEEE Int Conf on Systems, Man and Cybernetics* [C]. Washington, 2003, 2: 1298-1303
- [8] 佟知泽. 电梯常见故障及排除方法 [J]. *建筑电气*, 1993, 4: 41-43
(Tong Z Z. Frequent faults of elevator and its solving method [J]. *Architecture and Electric*, 1993, 4: 41-43)
- [9] 梁军尤. 电梯通道门故障分析 [J]. *机电工程技术*, 2001, 4: 51-52
(Liang J Y. Door fault analysis of elevator channel [J]. *Machine and Electricity Engineering Technology*, 2001, 4: 51-52)