



游张平

基于 FTA 和 FNN 的液压系统故障诊断方法研究

游张平,叶晓平,朱银法,胡笑奇

(丽水学院 机械工程学系,丽水 323000)

摘要:针对液压系统故障的复杂性和不确定性等特点,传统的故障推理方法难以满足液压系统故障诊断的要求,提出了基于故障树分析和专家经验知识的模糊神经网络故障诊断方法。以起重设备液压系统为研究对象,建立故障树模型,基于故障树信息和专家经验知识,建立模糊神经网络诊断模型及并提取训练数据,在此基础上,运用统计参数法确定模糊预处理所需的模糊隶属函数。将训练好的网络模型应用于实例诊断,实验结果验证了该方法的实用性和有效性。

关键词:液压系统;故障诊断;故障树分析;神经网络

中图分类号:TH137 **文献标识码:**A **文章编号:**1003-8728(2013)12-1855-04

A Hydraulic System Fault Diagnosis Method Based on FTA and FNN

You Zhangping, Ye Xiaoping, Zhu Yinfa, Hu Xiaoqi

(Department of Mechanical Engineering, Lishui University, Lishui 323000)

Abstract: The hydraulic system fault diagnosis method based on fuzzy neural networks (FNN), fault tree analysis (FTA) and expertise knowledge is proposed to overcome the shortcomings of the traditional fault diagnosis methods because of the complexity coupling and uncertainty of hydraulic system fault. Taking lifting equipment's hydraulic system as study object, a fault tree model is set up, and the fault tree information and expertise knowledge are employed to establish the FNN structure and extract training data. The fuzzy membership functions, which are needed in fuzzy pre-processing, are confirmed by using the statistical parameter method. Finally, the trained FNN model is applied to examples; the application results show that the hydraulic system fault diagnosis method based on FTA and FNN is effective and practicable.

Key words: efficiency; failure analysis; fault tolerance; fuzzy neural networks (FNN); fuzzy tree analysis (FTA); hydraulic machinery; knowledge based systems; mathematical models; membership functions; motors; neural networks; pressure; hydraulic system; fault diagnosis

液压系统具有体积小、重量轻、功率大、精度高、响应快及抗负载刚性大等优点,在许多重要领域得到了广泛应用。但由于诸多因素的影响,使液压系统

难免出现故障,且系统中各元件和工作液体都是在封闭油路内工作,使其故障具有以下特点:故障点的隐蔽性、故障因果关系的复杂性、故障相关因素的随机性、故障模式的多样性和失效分布的分散性^[1]。因此,传统的故障推理方法难以满足液压系统故障诊断的要求。文献[2]中运用故障树分析理论建立较为完善的中型挖掘机液压系统故障树模型;然而该方法计算速度较慢,而且难以包含丰富的概率知识和启发式知识^[3]。文献[4]中运用诊断效率高、实时性好的神经网络对液压系统进行故障诊断,然而学习样本的归纳一直是神经网络应用的一大难点^[5]。

收稿日期:2012-09-12

基金项目:国家科技支撑计划项目(2013BAC16B02),浙江省自然科学基金重点项目(LZ12F02001),丽水市公益性技术应用项目(2012JYB34),机械设计理论浙江省重中之重学科和浙江理工大学重点实验室基金项目(ZSTUMD2011A005)资助

作者简介:游张平(1978-),讲师,博士,研究方向为设备智能故障诊断和机电液控制技术,youzhangping@163.com

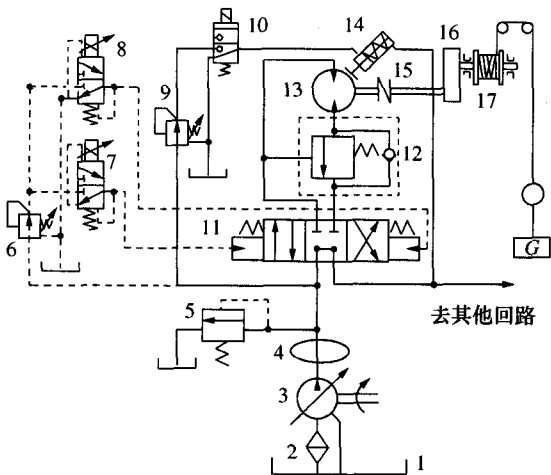
模糊神经网络兼具了模糊逻辑与神经网络的优点:它既可以模仿人脑的逻辑思维,又可以模仿人脑神经元的功能;既可以描述具有模糊概念的问题,又具有强大的学习能力和数据的直接处理能力:既具有较强的结构知识表达能力、自然语言处理能力,又具有很强的容错能力^[6]。一定程度上克服了基于符号的传统诊断专家系统存在的知识获取困难、知识存储容量与系统运行速度的矛盾和知识的窄台阶效应等问题,在知识获取、并行推理、自适应学习、联想推理和容错能力等方面显示出明显的优越性,非常适用于复杂对象的过程监测与故障诊断^[7,8]。另一方面,故障树描述和存储了系统关于故障树顶事件发生的全部知识,从故障树提取神经网络的训练数据可有效克服数据提取的盲目性,使神经网络学习数据的归纳简单易行。

因此,本文以工业上常用的某型起重设备液压系统起升回路为研究对象,将模糊神经网络和故障树相结合引入到液压系统故障诊断中,利用故障树信息和专家经验知识建立神经网络结构及并提取训练数据,在此基础上,运用统计参数法确定模糊预处理所需的模糊隶属函数。最后,通过实例验证了该方法的实用性和有效性。

1 模糊神经网络诊断模型的建立

1.1 故障树模型的建立

图 1 为某型起重设备 QY90 起升回路工作原理图。故障树模型描述和存储了系统关于故障树顶事件发生的全部知识。由于篇幅有限,这里仅给出“提升无动作”顶事件的故障树模型,如图 2 所示。并对该顶事件的各底事件进行了编码,如表 1 所示。



1. 油箱; 2. 滤油器; 3. 变量泵; 4. 回转接头; 5. 溢流阀; 6. 减压阀
7, 8. 比例减压阀; 9. 减压阀; 10. 二通电磁阀; 11. 换向阀; 12. 平衡
阀; 13. 卷扬马达; 14. 液压缸; 15. 联轴器; 16. 减速器; 17. 卷筒

图 1 液压系统图

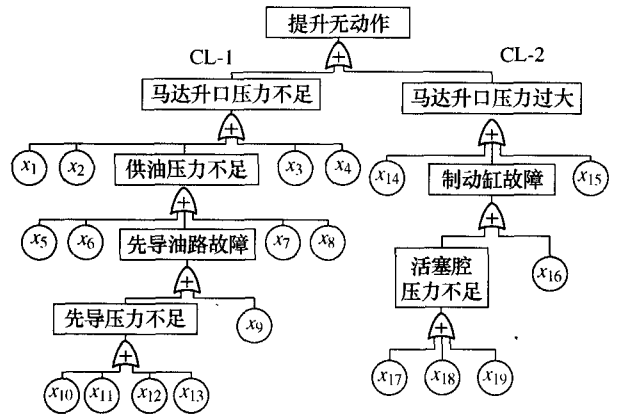


图 2 “提升无动作”故障树模型

表 1 底事件编码表

代号	事件名称
X ₁	马达泄漏
X ₂	换向阀杆卡死
X ₃	卷扬离合器打滑
X ₄	回转接头泄油
X ₅	油箱油量不足
X ₆	过滤器阻塞
X ₇	溢流阀故障
X ₈	变量泵故障(磨损)
X ₉	先导油路回油堵塞
X ₁₀	手柄损坏
X ₁₁	控制器输出故障
X ₁₂	比例减压阀损坏
X ₁₃	减压阀 6 故障
X ₁₄	卷扬马达卡死
X ₁₅	卷扬减速器故障
X ₁₆	制动器卡死
X ₁₇	减压阀 9 故障
X ₁₈	二通电磁阀故障
X ₁₉	制动缸活塞磨损

1.2 模糊神经网络诊断模型的建立

表 1 的 19 个底事件中,每个独立的底事件就是一个最小割集。根据图 2 的故障树知识可知,共有 2 个支路会导致故障树顶事件的发生。支路 CL-1 表示马达升口压力不足直接造成提升无动作的事件链。支路 CL-2 描述了马达升口压力过大的故障异常原因。因此,可以建立 2 个模糊神经网络分别对支路 CL-1 与支路 CL-2 进行并行诊断,然后根据故障树各分支中所蕴含的知识确定各自网络的结构。

限于篇幅,这里以支路 CL-2 为例。支路 CL-2 包括 6 个最小割集为卷扬马达故障(底事件 14)、卷扬减速器故障(底事件 15)、制动器卡死(底事件 16)、减压阀 9 故障(底事件 17)、二通电磁阀故障(底事件 18)、制动缸活塞磨损泄漏(底事件 19)。

设备在正常工况下马达是不会出现憋压的,而以上 6 个最小割集的任一个最小割集发生都会引起马达憋压,马达升口压力 P_m 过大。最小割集 X_{14} 或 X_{15} 的发生,不会对制动缸控口压力 P_d 产生影响,而 X_{16} 的发生会使 P_d 值高出正常范围值且有较大的压力波动, X_{17} 、 X_{18} 或 X_{19} 的发生则会使 P_d 值低于正常范围值,但 X_{19} 的发生会使 P_d 保持较大的压力波动,而 X_{17} 或 X_{18} 的发生会使 P_d 则保持较小的压力波动。 P_d 的压力波动情况可以采用其均方差 D_{pd} 来表征。系统仅需通过对 P_m 和 P_d 的状态检测,获得 3 个输入变量: P_m 、 P_d 、 D_{pd} ,便可区分以下 5 种故障模式:正常工作、 $\{X_{14}$ 或 $X_{15}\}$ 、 X_{16} 、 $\{X_{17}$ 或 $X_{18}\}$ 、 X_{19} 。由此可确定支路 CL-2 对应的模糊神经网络结构具有 3 输入 5

输出的结构,隐含层神经元节点数根据经验取为 6,即 $3 \times 6 \times 5$,如图 3 所示。其中,隐层中的神经元采用对数 Sigmoid 型函数,输出层的神经元采用纯线性 purelin 变换函数。




图 3 模糊神经网络诊断模型

2 训练样本的提取

根据上述分析,提取模糊神经网络的训练样本数据,如表 2 所示。

表 2 神经网络训练样本

样本号	故障模式	对应故障	输入模式			输出模式				
			∂_m	∂_d	D_{pd}	y_1	y_2	y_3	y_4	y_5
1	F_1	正常工作	0.5	0.5	0.5	1.0	0.0	0.0	0.0	0.0
2	F_2	X_{14} 或 X_{15}	0.9	0.5	0.5	0.0	1.0	0.0	0.0	0.0
3	F_3	X_{16}	0.9	0.9	0.9	0.0	0.0	1.0	0.0	0.0
4	F_4	X_{17} 或 X_{18}	0.9	0.1	0.1	0.0	0.0	0.0	1.0	0.0
5	F_5	X_{19}	0.9	0.1	0.9	0.0	0.0	0.0	0.0	1.0

表 2 中: ∂_m 取值 0.1、0.5、0.9 分别表示马达升口压力 P_m 过低、正常、过高; ∂_d 取值 0.1、0.5、0.9 分别表示 P_d 制动缸控口压力过低、正常、过高, D_{pd} 取值 0.1、0.5、0.9 分别表示制动缸控口压力均方差过低、正常、过高。

3 模糊隶属函数的建立

首先,依据输入变量的样本集在输入变量取值区间的分布情况确定每个输入变量的隶属函数。这里,状态变量域低的转换采用降半梯形分布的隶属函数,其表达式为

$$\mu(x;a,b) = \begin{cases} 1 & x \leq a \\ \frac{b-x}{b-a} & a < x < b \\ 0 & x \geq b \end{cases} \quad (1)$$

确定权值系数为 0.1。

状态变量域正常的转换都采用梯形分布的隶属函数,其表达式为

$$\mu(x;c,d) = \begin{cases} 0 & x \leq c \\ \frac{x-c}{d-c} & c < x < d \\ 1 & x \geq d \end{cases} \quad (2)$$

确定权值系数为 0.5。

状态变量域高的转换采用升半梯形分布的隶属函数,其表达式为

$$\mu(x;a,b,c,d) = \begin{cases} 0 & x \leq a \\ \frac{x-a}{b-a} & a \leq x \leq b \\ 1 & b \leq x \leq c \\ \frac{d-x}{d-c} & c \leq x \leq d \\ 0 & d \leq x \end{cases} \quad (3)$$

确定权值系数为 0.9。

其中权值的设定是为了处理处于两个状态间的检测数据,利用各隶属函数的加权平均的方法将处于两状态间的数据转换成模糊数据。

其次,确定隶属函数各参数的值。设备正常工作时的诊断参数 y 服从正态分布规律,对正常工作时的诊断参数收集一定量的样本数据,对这些数据进行统计处理,如果测试样本与均值 \bar{Y} ; 距离在 2 倍或 3 倍方差以上,则认为该测试样本是不确定的,故可判为异常^[9]。于是可以得到报警界限:故障界限(参数值偏高或偏低)为 $\bar{Y} \pm 3\sigma$; 参数正常界限为 $\bar{Y} \pm \sigma$ 。这便是 3σ 准则。为获得更符合客观实际的隶属函数,使上文建立的模糊网络模型进入实际应用,

本文运用统计参数法中的 3σ 准则法确定隶属函数各参数的值。对输入变量(P_m 、 P_d 、 D_{Pd})的样本数据应用 3σ 准则法,得到各输入变量的隶属函数参数 a 、 b 、 c 、 d 的值,接着代入到式(1)~(3),便得到了各输入变量的隶属函数,即确立了模糊神经网络的隶属函数。图4为应用 3σ 参数统计法得到的神经网络输入变量卷扬马达升口压力 P_m 的隶属函数参数值曲线。

同理,可得到制动缸控口压力 P_d 隶属函数参数值为: $\{a, b, c, d \mid \text{制动缸压力(bar)}\} = \{36.1001, 36.3344, 36.5688, 36.6031\}$ 。为了使制动缸控口压力均方差 D_{Pd} 的隶属函数参数值的计算也可应用 3σ 参数统计法,选取 m 个连续数据求取均方差后进行滑动处理; m 越大越能反映真实的情况,然而 m 选取过大会影响在线诊断的实时性,这里取50,最后应用 3σ 参数统计法得到 D_{Pd} 的隶属函数参数值为: $\{a, b, c, d \mid \text{制动缸压力均方差}\} = \{0.0294, 0.0733, 0.1173, 0.1613\}$ 。




图4 卷扬马达升口压力的隶属函数参数值曲线

4 诊断实例及结果分析

为验证上文所建立的模糊神经网络故障推理模型的有效性,将之应用于起重机的在线故障诊断。首先,将上文提取到的表2训练样本,应用Levenberg-Marquardt算法对模糊神经网络模型进行训练,经过4次优化计算迅速收敛,目标函数达到 1.93659×10^{-6} ,得到良好的效果。接着,将输入变量数据进行模糊量化预处理后,送入训练好后的神经网络进行计算,获得输出层各神经元的输出 Y_j ($j = 1, 2, \dots, 5$),最后根据阈值原则判断故障状态及原因事件:当 $Y_j \geq 0.8$ 时,表示故障模式 F_j 发生;当 $0.4 \leq Y_j < 0.8$ 时,表示故障模式 F_j 可能发生。

已知(298.6843, 0.773, 0.0327)是一组马达升口压力、制动缸控口压力及制动缸控口压力均方差实际工况数据。将该组工况数据经模糊化后,各输入变量对各自论域的隶属度为(0.9000, 0.1000, 0.1608),经过网络计算得到输出为:

(-0.0321, -0.1047, 0.0381, 0.9932, 0.1031),按上述判别原则可判断该故障对应的故障模式为 F_4 ,即最小割集 X_{17} 减压阀9故障或最小割集 X_{18} 二通电磁阀故障。实际状况是二通电磁阀断接。诊断结果与实际状况一致。

另外,模糊神经网络对空载和40T(钢丝绳倍率为8)无故障工况下的输入变量数据进行计算,输出结果分别为(0.9996, -0.0012, -0.0002, 0.0001, -0.0015)、(0.9418, 0.1473, -0.0744, 0.0250, -0.0419)。由此可知,网络对这两者都做出了正确的判断:系统对应的故障模式为 F_1 ,即系统正常工作,无故障。

5 结论

模糊神经网络在知识获取、并行推理、自适应学习、联想推理和容错能力等方面显示出明显的优越性,而故障树描述和存储了系统关于故障树顶事件发生的全部知识,从故障树提取神经网络的训练数据可有效克服数据提取的盲目性,使神经网络学习数据的归纳简单易行。本文结合某型起重设备液压系统故障诊断证明:应用模糊神经网络和故障树相结合的诊断方法对大型复杂液压设备故障进行判断具有较好的应用价值。

[参考文献]

- [1] 周汝胜,焦宗夏,王少萍. 液压系统故障诊断技术研究现状与发展趋势[J]. 机械工程学报, 2006, 42(9): 6-14
- [2] Ma C, Wang K S, Sun J H. Fault diagnosis to mid-size excavator hydraulic system based on fault tree analysis[C]// 2010 International Conference on Frontiers of Manufacturing and Design Science, 2010
- [3] 向长城. 基于可拓学的智能故障诊断与状态监测的理论及应用研究[D]. 重庆大学, 2008
- [4] He X Y, Shao Y M, He S H, et al. Fault diagnosis of hydraulic system using dynamic GRNN[J]. ICIC Express Letters, 2011, 5(8A): 2617-2623
- [5] 陈炜,吴志良. 故障诊断专家系统结合故障树技术的结构研究[J]. 航海技术, 2005, (6): 43-44
- [6] Pisu P. Hierarchical model-based fault diagnosis with application to vehicle systems[C]// 15th Triennial World Congress, Barcelona, Spain, 2002
- [7] 张敬芬,孟光,赵德有. 基于模糊神经网络的薄板不同指标裂纹诊断[J]. 机械工程学报, 2006, 42(3): 145-149
- [8] Yznaga B I, Sun D, He Y K. Neural-fuzzy technique for inverter faults diagnosis in PMSM DTC system[J]. Electric Machines and Control, 2008, 12(3): 132-139
- [9] Pltkesheim F. The three sigma rule[J]. The American Statistician, 1994, 48(2): 88-91