

采用神经网络技术降低机电设备 BIT 虚警^{*}

徐永成 陶利民 温熙森 易晓山

(国防科技大学机械电子工程与仪器系 长沙 410073)

摘要 机电设备 BIT 的突出问题是虚警率高,重要原因之一是 BIT 系统传感器通路故障。本文选取神经网络技术进行传感器通路故障诊断,剖析某大型船舶动力装置机电设备 BIT 系统中传感器通路的故障机理和类型,得到其故障样本数据,经过神经网络学习训练后对实际系统进行故障诊断和识别,实验结果表明该方法简洁、有效,能够有效地诊断故障并识别出故障类型,具有实用价值。

关键词 机内测试,故障诊断,虚警,神经网络

分类号 TN06

Decreasing False Alarm of Mechantronics Equipment Built-in Test Based on Neural Network

Xu Yongcheng Tao Liming Wen Xisen Yi Xiaoshan

(Department of Mechantronics Engineering and Instrumentation, NU DT, Changsha, 410073)

Abstract The significant problem of mechantronics equipment built-in test (MEBIT) is its high false alarm rate. One of the important causes is its sensor channel's fault of BIT system. The method of neural network is adopted for the sensor channel fault diagnosis. The fault mechanism and types of sensor channels of MEBIT in a large ship power engine and the fault samples are obtained. After the training of neural network, the actual system's faults are diagnosed and identified. The experimental results show that the neural network can diagnose the faults and identify their types. The method is compact, effective and of practical value.

Key words built-in test, fault diagnosis, false alarm, neural network

机内测试(Built-in Test, BIT)技术在电子设备中取得了多方面成功的应用,机电设备 BIT (mechantronics equipment built-in test, MEBIT)是 BIT 发展的一个重要方向^[1,2]。但是 BIT 技术在机电领域同样面临诊断能力差和虚警率高两方面的问题。机电设备 BIT 的虚警原因很多,涉及到传感器选择、测点选取、信号采集传输中的失真、电磁干扰以及数据处理和决策方法不当等很多方面。在机电设备 BIT 总体设计、传感器和测点选择已经完成之后,MEBIT 运行过程中产生虚警的重要原因之一就是传感器通路故障。事实上,传感器通路往往工作在高温、高湿、强震等恶劣环境中,是整个 MEBIT 系统中比较容易出现故障的环节,故障类型包含硬故障(物理损坏)和软故障(性能降低),它们会导致整个系统工作不正常,MEBIT 的虚警率升高。为了保证机电设备 BIT 的正常运行,减少虚警,必须对传感器通路进行故障诊断和识别,然后采取相应对策,或者调用备份传感器通路,或者运用重构容错方法继续运行。

1 传感器通路故障诊断技术

传感器通路的故障诊断理论和方法主要可以分为硬件冗余法、解析冗余法、混合冗余法、神经网络法等几类。硬件冗余法要求有三个或三个以上同类传感器,以多数表决的方式检测、隔离传感器故障,设计简单,但成本太高;解析冗余法是通过建立系统模型(静态或动态),运用卡尔曼滤波器等方法检测

* 国家部委基金项目资助
1999年1月12日收稿
第一作者:徐永成,男,1972年生,博士生

传感器故障, 然而当系统存在高度非线性而难以得到其数学模型时, 这种方法将无能为力, 因而该方法具体实施难度较大, 不易开展, 目前主要限于理论和仿真研究^[3]; 混合冗余法通常是用双硬件冗余加上解析冗余, 要求已知系统动态特性和干扰噪声的精确模型, 计算量和计算难度较大, 但在一些重要场合仍有应用研究; 现在有很多学者在研究基于神经网络的传感器通路故障诊断方法, 神经网络可以完成输入/输出的复杂映射, 容错能力强, 运行速度快(在已经进行良好样本训练的基础上), 更重要的优点是它不需要系统的精确数学模型, 这在设计应用系统中显得尤为重要。正是由于这些特点, 采用神经网络方法进行传感器通路故障诊断取得了不少成果^[4]。

2 MEBIT 系统传感器通路故障机理分析

某大型船舶动力装置是一个典型的复杂机电设备, 它包含锅炉、主汽轮机和五套发电机组, 由于动力装置运行环境较为恶劣, 是事故的高发区域, 因此为很好地监测其运行状况, 及时报警并进行故障诊断和识别, 设计了一套能够监测各部件主要运行参数和状态, 并能进行故障诊断的 BIT 系统, 该系统的传感器安装、传输电缆走线、所需电源、测控平台等都与系统功能模块并行设计, 与之有机结合。

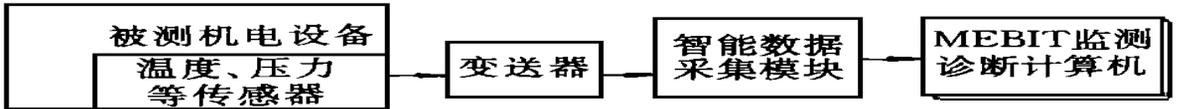


图 1 MEBIT 系统传感器通路示意图

Fig. 1 Sketch map of sensor channel of MEBIT system

在 BIT 系统运行过程中, 发现传感器通路故障是 BIT 系统发生虚警的主要来源, 该 MEBIT 系统传感器通路示意图参见图 1。经过大量现场实验和分析, 发现有如下一些可能发生的传感器通路故障(以下都以热敏电阻、热电偶温度传感器通路为例):

(1) 热电偶传感器输入端断路; (2) 热电偶传感器输入端短路; (3) 热敏电阻传感器输入端断路; (4) 热敏电阻输入端短路; (5) 热敏电阻变送器电源线断路; (6) 热电偶变送器电源线断路; (7) 热电偶变送器输入端正负端接反; (8) 热电偶冷端补偿线断路; (9) 传感器通路漂移(零漂、灵敏度漂移)。

在实际运行过程中, 我们发现传感器本身出现故障的几率较小, 但是由于外围安装、设计和使用过程中容易出现各种各样的问题: 如装夹不当引起传感器破裂、传感器接头焊接不当、变送器连接件松脱等等, 这些故障往往引起 MEBIT 的虚警。上述传感器通路故障的有效诊断和识别对提高 MEBIT 的诊断能力和报警可信度是非常重要的。

3 神经网络方法诊断传感器通路故障

3.1 传感器的标定

试验系统中实际采用热敏电阻和热电偶两种测温传感器。测温之前必须对这两个传感器通路进行标定, 标定效果的好坏对传感器通路故障自诊断的精确度有较大影响。图 2 为这两种传感器通路在 0 ~ 100 范围内的一阶线性拟合标定结果图。这是基于最小方差意义上的拟合, 之所以只进行一阶线性拟合, 既是为了计算方便, 对于实际测量需求而言, 一阶线性也已足够。结果为:

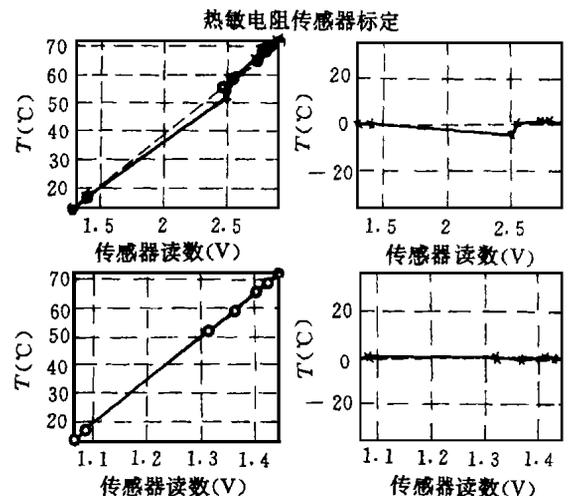


图 2 传感器标定与曲线拟合

Fig. 2 Sensor calibration and curve fitting

$$t_1 = 36.4231v_1 - 34.2611$$

(1)

$$t_2 = 153.2718v_2 - 149.3971 \tag{2}$$

其中 t_1, t_2 分别对应热敏电阻、热电偶传感器测得温度值(单位: $^{\circ}\text{C}$), v_1, v_2 对应这两通路测得的电压值(单位: V)。

3.2 神经网络诊断算法

现在对各种各样神经网络算法的研究很多,但实际应用最多的还是 BP 系列算法,原因在于它的简单、实用(如同控制算法中的 PID)。通常情况下 BP 系列算法的性能也可以达到要求,因此本文采用 BP 系列算法。经过实验研究发现采用 BPX 算法(即在传统 BP 算法的基础上,加上动量矩和自适应参数调节)比传统 BP 算法只增加极少的计算量(而且这种增加仅限于神经网络训练、学习阶段),但是训练时收敛速度快、收敛过程稳定,因而采用 BPX 算法进行传感器通路故障样本的训练和学习。因为对传统 BP 算法的阐述在很多文献上都可见到^[5],在此不作赘述。

3.3 传感器通路故障样本的采集、处理、训练及故障诊断

本实验采集每种故障样本的数据各 100 组,首先将其进行归一化处理:

$$x_i = x_{oi} / \max(x_{oi}) \tag{3}$$

式中 x_1 ——归一化后的结果; x_{oi} ——原始采集数据; $\max(x_{oi})$ ——原始采集数据 x_{oi} 中的最大值。这样把原始数据线性归一化到 $[0, 1]$ 区间内,其中每组数据里包含三路输入:一路热敏电阻、一路热电偶、一路 5V 标准电压。将其中 10 组数据编为神经网络的输入序列进行学习训练,部分故障样本数据、对应传感器通路故障类型和对应的神经网络目标输出值参见表 1。在该表中,由于热电偶的测量输出值与实际温度值并非严格线性关系,实际是一种非线性关系,这种非线性在低温段表现较为突出,所以在 14.24 $^{\circ}\text{C}$ 时热电偶的测量输出按照上述一阶线性拟合公式得到的温度值为 17.49 $^{\circ}\text{C}$,误差为 3.05 $^{\circ}\text{C}$,处在正常误差范围内。

表 1 神经网络传感器通路故障诊断数据表
Tab. 1 sensor channel fault diagnosis data table based on neural network

故障类型	归一化输入序列			原始数据采集样本群(V)			温度值($^{\circ}\text{C}$)		输出
正常状况	0.2663	0.2177	1.00	1.3315	1.0886	5.00	14.24	17.49	0.1
热电偶断路	0.2664	1.0000	1.00	1.3320	5.0000	5.00	14.25	616.97	0.9
热电偶短路	0.2665	0.2253	1.00	1.3326	1.1264	5.00	14.28	23.26	0.2
热电阻断路	1.0000	0.2198	1.00	5.0000	1.0991	5.00	147.9	19.07	0.4
热电阻短路	0.1702	0.2204	1.00	0.8512	1.1074	5.00	-3.26	20.35	0.5
热电阻变送器断路	0.0000	0.2184	1.00	0.0001	1.0918	5.00	-34.3	18.01	0.6
热电偶变送器断路	0.2664	0.0001	1.00	1.3320	0.0003	5.00	14.26	-149.3	0.7
热电偶变送器输入接反	0.2663	0.3633	1.00	1.3314	1.8167	5.00	14.23	129.1	0.8
热电偶冷端补偿线断路	0.2666	1.0000	1.00	1.3332	5.0000	5.00	14.29	616.9	0.9
传感器漂移(零漂、满漂)	0.1757	0.1271	0.91	0.8783	0.6354	4.55	-2.27	-51.99	1.0

网络采用双隐层结构:30-12-6-1,输入层 30 个节点分别对应 10 组热敏电阻输入、10 组热电偶输入和 10 组 5 伏特输入,在网络结构设计中,选取每路输入对应 10 个节点的主要原因是,这样可以排除输入数据中混入的干扰噪声影响,增加该分类诊断网络的鲁棒性。两个隐层节点数分别为 12、6,输出层节点为 1,其取值范围从 0 到 1,依次对应传感器通路的 10 种状态类型。网络采用双隐层结构的主要原因是:输出层只选取了一个输出节点,为了保证诊断网络的良好分类能力和收敛速度。网络训练参数为:

$$\eta = 0.01, a = 1.05, b = 0.7, \alpha = 0.9,$$

$$E = 0.002$$

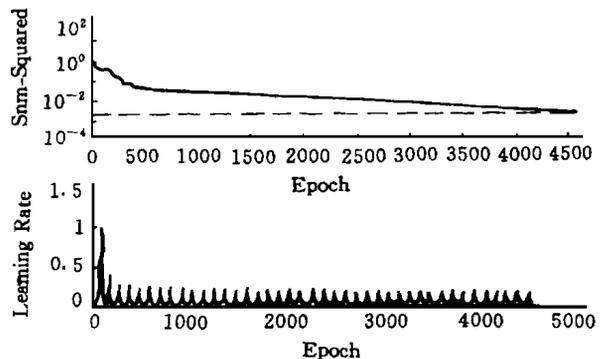


图 3 网络训练误差曲线及学习率曲线

Fig. 3 network learning error, learn rate curve

其中 η 为学习速率, a 为学习速率增加量, b 为学习速率减小量, α 为动量矩系数, E 为收敛误差。

采用上述快速 BP 算法, 迭代次数为 4584 后达到精度要求, 训练过程中误差函数曲线和学习率变化如图 3 所示。得到一组较为满意的网络节点权值和偏差值, 保存该网络结构和训练参数, 便于在系统实际运行中进行实时传感器通路故障诊断和识别。为了验证该网络的正确性, 从实际采集数据集中另取 10 组数据输入该网络, 进行故障识别校验, 所得网络输出结果如表 2 所示。

表 2 神经网络传感器通路故障诊断与识别运行结果

Tab. 2 results of sensor channel fault diagnosis based on neural networks

状态类型编号	1	2	3	4	5	6	7	8	9	10
网络理想输出	0.1	0.9	0.2	0.4	0.5	0.6	0.7	0.8	0.9	1.0
实际运行输出	0.1321	0.8967	0.1684	0.4006	0.4977	0.6024	0.6986	0.8057	0.8967	0.9980

3.4 分析与讨论

(1) 网络结构对整体性能影响较大, 本文选取输出层节点为 1 的结构, 相对于人们通常在这种情况下选取的与故障样本类型数相同的输出节点数的方法而言, 更加简洁, 且实验表明该方法是有用的;

(2) 对于热电偶传感器断路和热电偶变送器冷端补偿线断路这两种故障类型, 由于它们的输出读数不能反映出它们的区别, 因而不能区分这两种故障, 实际应用时只能作为一类故障看待;

(3) 由于 BIT 系统传感器通路的一些故障模式的输出特征并不固定(例如热电偶变送器输入端正负接反), 而且其测量输出值也处于测量正常范围内, 因而用简单的固定逻辑判断不能识别这些传感器通路故障模式, 所以使用上述基于模式相关的神经网络分类方法的适用范围更广;

(4) 神经网络样本获取越全面, 样本间距越大, 其训练、运行效果越好, 因此对样本的获取、预处理、归一化过程的深入研究, 能够大大改善网络分类性能, 本文中选取的样本群内各样本间距一般较大, 分类效果较好, 但是系统正常状态与热电偶传感器输入短路这两种情况, 由于样本间距较小, 所以分类效果受影响, 但是这两种情况在温度变化过程中能够予以区分, 因此只要改变工况, 重新获取样本即可很好识别该类故障;

(5) 对于热电偶变送器输入接反和传感器通路漂移故障, 在温度明显变化时才能更好地加以区分, 特别是对于零漂和满漂, 如果不在温度变化过程中是无法很好地区分的(因为在一个稳定不变的温度的情况下, 它们的故障现象是一样的)。

4 结论

实验结果表明, 在大型船舶动力装置 MEBIT 系统内部传感器通路故障的自诊断过程中, 神经网络方法能够有效地判断出故障的有无, 并识别出故障的类型, 从而提高了整个 MEBIT 系统自身可靠性, 减少了因为 MEBIT 系统自身故障造成的 BIT 虚警, 具有应用价值和实际意义。

参考文献

- 1 温熙森, 徐永成, 易晓山. 智能理论在 BIT 设计与故障诊断中的应用. 国防科技大学学报, 1999, 21(1): 87~101
- 2 Richard D S. F-111/TF30 Engine Monitoring System A Fusion of Past, Present, And Future Technology. IEEE 1989 AUTOTEST-CO N, 1989: 2062~2069
- 3 钮永胜, 赵新民, 孙金玮. 传感器故障诊断方法研究. 航天控制, 1996(4): 47~49
- 4 Napolitano M R. Neural-network-Based Scheme for Sensor Failure Detection, Identification and Accommodation. AIAA Journal of Guidance, Control and Dynamics, 1995, 18(6): 1280~1286
- 5 R Hecht-Nielsen. Theory of the Backpropagation neural network. IJCNN'89, 1989, (1): 593~605