

文章编号: 1671-6612 (2020) 03-316-05

基于 BP 神经网络的小型民机蒸发循环制冷系统故障诊断研究

王玉兵¹ 孙程斌² 徐雷³ 高赞军¹ 王炬¹

(1.中国航空工业集团公司金城南京机电液压工程研究中心 南京 210006;

2.南京航空航天大学航空学院 南京 210016;

3.金陵科技学院 南京 211169)

【摘要】 针对 B787 蒸发制冷循环系统中常见的 9 种典型故障进行实验模拟, 建立 BP 神经网络故障诊断推理模型对故障进行在线诊断, 诊断准确率达到 90% 以上。同时, 为满足健康管理对“时效性”和“准确性”的故障检测本质要求, 对几种 BP 寻优算法及其他相关参数进行了对比分析, 优化 BP 神经网络结构, 并采用主元分析法前处理故障数据, 满足泛化误差要求的同时, 从整体上降低了网络计算时间, 为故障在线诊断的“时效性”提供良好保障。

【关键词】 民机蒸发循环; 故障诊断; 神经网络; 优化

中图分类号 V245 文献标识码 A

Research on Fault Diagnosis of Small Civil Aircraft Evaporative Circulation Refrigeration System Based on BP Neural Network

Wang Yubing¹ Sun Chengbin² Xu Lei³ Gao Zanjun¹ Wang Ju¹

(1.Aviation Key Laboratory of Science and Technology on Aero Electromechanical System Integration, Nanjing, 211106;

2.Nanjing University of Aeronautics and Astronautics, Nanjing, 210006;

3.JinLing Institute of Technology, Nanjing, 211106)

【Abstract】 9 typical faults in the B787 evaporative refrigeration cycle system was simulated by experiment, and the BP neural network was established to diagnose the fault online using the data acquired from experiment, the results showed that diagnostic accuracy reached more than 90%. At the same time, in order to meet the essential requirements of health management for "timeliness" and "accuracy", several BP optimization algorithms and other related parameters were compared, which optimizing the BP neural network structure, and principal component analysis was used to pre-processing fault data. It revealed that the approach met the generalization error requirements and reduced the network computing time as a whole, providing a good guarantee for the "timeliness" of fault online diagnosis.

【Keywords】 civil aircraft evaporation cycle; fault diagnosis; neural network; optimization

作者简介: 王玉兵 (1980.2-), 男, 硕士, 研究员, E-mail: wangyb@neias.cn

通讯作者: 孙程斌 (1992-), 男, 在读博士研究生, E-mail: 346945396@qq.com

收稿日期: 2019-06-27

0 引言

随着民用航空技术的发展,民用小型飞行器的安全性、可靠性及安全保障体系的经济有效性等已经成为发展民用航空技术中至关重要的关键问题^[1]。小型蒸发循环制冷系统是民用飞行器环控系统中的重要组成部分,小型蒸发循环制冷系统健康管理技术则是目前主要集中在系统部件、子系统的故障诊断与预测上,以故障诊断与预测为技术核心,发展出基于诊断模型、预测规则、关键参数测量等方法,但仍有故障诊断不全面、故障产生与传播不清晰、误报率高、系统级故障相关性不明显、预测精度低、生命周期成本利用率低等问题^[2]。

研究民机蒸发循环制冷系统中的故障产生、发展和传播的机制,并建立诊断和预测的模型构架^[3],选择并集成合理的系统诊断与预测方法,提

高监测、监测系统的信息利用率,实现对系统故障的多角度、多参数诊断与预测^[4],完善和提高民机蒸发循环制冷系统诊断和预测水平。

1 BP神经网络的故障诊断模型

1.1 故障诊断模型

利用神经网络智能诊断方法对民机蒸发循环制冷系统进行故障诊断,首先要从数据库中获取先验信息,建立系统正常工作状态以及不同故障模式的样本数据,形成系统故障数据库,并进行样本的学习和训练。在训练之后,在特征参数偏离健康阈值的状态下,执行对相应子系统的故障诊断与预测,判断子系统是否会发生故障,并确定故障模式^[5]。训练及故障诊断流程如图1所示。

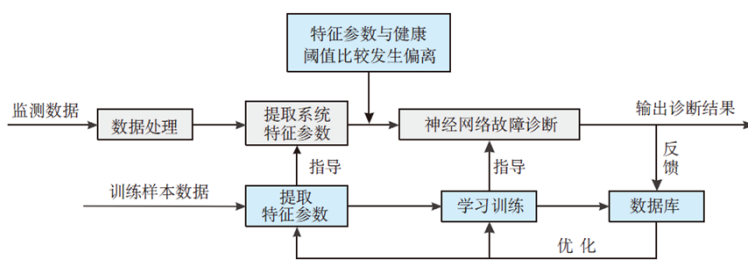


图1 民机蒸发循环制冷系统故障诊断流程

Fig.1 Fault diagnosis process for civil aircraft evaporative refrigeration cycle system

1.2 BP神经网络设计

创建一个具有20个隐含层神经元的BP神经网络,隐含层和输出层均使用弓形传递函数:

$$f_n = \frac{1}{1 + e^{-n}} \tag{1}$$

预处理输入数据和输出数据不仅加速了网络的训练,同时促进了网络的计算收敛,使不同量纲之间的元素具有一定的可比性。网络的初始权值和阈值的元素随机设置在[0,1]范围内,用近似平均方差作为性能指标函数,采用最陡梯度下降法更新权值和阈值。建立的BP网络结构如图2所示。




图2 BP神经网络结构

Fig.2 BP neural network structure

使用不同的故障类型数据和正常工况数据作为神经网络的输入,通过系统实际参数输出与网络期望输出的迭代更新来获得最佳的BP神经网络权重和阈值^[6],从而获得BP神经网络推理模型。

2 蒸发循环制冷故障模拟实验系统

2.1 实验系统组成




图3 喷气增焓式蒸发循环制冷系统实验台

Fig.3 Jet-enhanced evaporative refrigeration cycle system test bench

为获得系统不同故障类型的数据及正常运行工况数据,设计搭建了一套喷气增焓式蒸发循环制冷系统实验台,如图3所示。对机载蒸发循环制冷系统的常见故障进行模拟,建立故障诊断程序所需的训练样本,并分析机组运行参数和故障之间的关系。

实验系统由三部分组成:制冷系统、循环/载冷水系统及电控系统。数据采集系统由西门子200模块、Pt100温度传感器和压力传感器组成,系统采集的信号通过西门子200数据采集设备与PC机通讯,实现数据的连续采样和记录。软件采用组态软件将数据存储存储在PC机样本数据库中。

2.2 测量系统设计

系统关键位置状态点测量是实现故障检测和诊断功能的基础。机载条件下,制冷系统具有多种故障特征、系统的各种物理参数互相关联、部分系统参数难以测量等特点^[7],因此在实验中,监测测点的选择应考虑以下原则:

(1) 测量集的完备性。所选取的制冷系统物理参数测量集为制冷系统物理参数的一个子集。以常见的正常工况和故障构成描述对象空间,测量集相对于该描述空间具有完备性;

(2) 测量的可扩充性。考虑实验预选的测量集可能不具有完备性,需要在实验系统中增加冗余测量安装位置,便于对测量集进行扩充;

(3) 测量的精简性。在基于模式识别的故障诊断系统中,参数集的冗余性会增加故障检测与诊

断的传感器数目,增加系统的成本,增加诊断运算量与运算时间。




图4 实验系统测点布置

Fig.4 Experimental system point arrangement

如存在一组参数,在正常工况下满足一定函数关系,但在故障工况下呈现不同的变化趋势,则该组参数对测量集不构成冗余,需要保证参数的完备性^[8]。实验台设计的测点布置如图4所示,包括:蒸发器供/出水温度 T1/T2, 冷凝器供/出水温度 T3/T4, 冷凝器制冷剂进/出口温度 T5/T6, 膨胀阀进口温度 T7, 蒸发器制冷剂进/出口温度 T8/T9, 闪发温度 T10, 补气温度 T11, 冷凝器制冷剂进/出口压力 P1/P2, 膨胀阀进口压力 P3, 蒸发器制冷剂进/出口压力 P4/P5, 闪发压力 P6, 补气压力 P7, 共计18个测量点。

2.3 实验模拟故障设计

机载蒸发循环制冷系统中的部件形式多样、选择繁多,系统故障的部件与原因种类复杂^[9]。根据故障影响系统的方式,分为突发性故障和渐变性故障。突发性故障指某一部件短时间内完全停止工作,导致系统无法运行或者严重偏离正常工况的故障,如:压缩机停机、阀门堵死、风机停转等。突发性故障影响严重,但症状明显、易察觉,便于及时采取维护措施。渐变性故障指系统偏离逐渐积累产生的、短时间内系统运行无显著影响的故障,如:冷凝器结垢、制冷剂泄漏、冷冻水量不足等。渐变性故障发作周期长、不易察觉,当故障征兆明显时,系统已带障运行较长时间,系统部件易产生损害,能耗增大。

针对机载蒸发循环制冷系统的运行特点,对9种典型的渐变故障工况进行了模拟,包括:补气管路堵塞、不凝性气体、冷凝器堵塞、冷却水不足、

载冷水不足、蒸发器堵塞、冷却不足、制冷剂欠充、制冷剂过充。实验数据经过处理形成机载蒸发循环制冷系统渐变故障数据库, 使用 BP 神经网络进行训练仿真。

3 诊断模型验证与优化

3.1 BP 诊断模型验证

在 MATLAB 中建立 BP 神经网络模型, 设置隐含层神经元个数和基本参数, 网络通过 58 次迭代, 用时 14s, 学习目标为均方根误差 MSE 小于设定值 10^{-4} , 迭代结束, 权值和阈值更新完毕, 图 5、6 所示为误差迭代曲线与历史误差分布。误差迭代曲线中显示神经网络的训练误差降到 $1e^{-4}$, 检验样本的误差降到 $1e^{-3}$, 而测试样本的误差降到 $1e^{-3}$ 以下, 说明学习目标已经达到。训练误差集中于 0 附近, 网络训练精度较高。

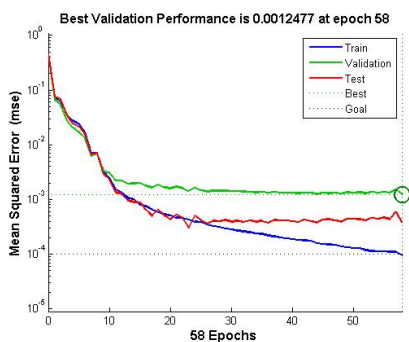


图 5 误差迭代曲线

Fig.5 Error iteration curve

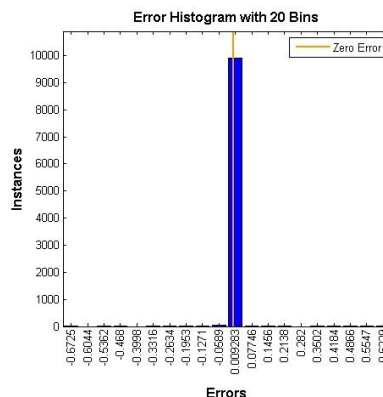


图 6 历史误差柱状图

Fig.6 Bar chart of historical error

对实验所得 400 个不同训练样本的故障集进行推理模型验证, 验证结果如图 7 所示。

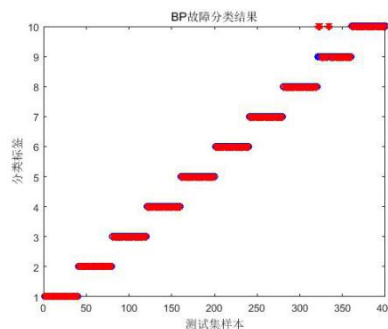


图 7 故障诊断结果

Fig.7 Fault diagnosis results

设计的 BP 神经网络对系统的故障诊断综合准确率为 95%, 对于前 8 种系统运行状态能准确判断, 准确率接近 100%, 但对制冷剂过充故障的诊断率仅为 50%, 原因可能是储液罐或者闪发罐等设备过充时, 系统参数和正常状态时很接近, 另一方面, 该故障在实际情况中发生概率较小, 且对于拥有储液罐或闪发罐的系统影响较小。

3.2 BP 诊断模型参数优化

通过对学习算法、学习目标与隐含层节点数三个参数的选择, 根据参数构建正交表 $L_{16}(4^5)$, 如表 1 所示。

表 1 正交实验分析表

Table 1 Orthogonal experimental analysis table

| 试验号 | 因素 | 学习算法 | 学习目标 | 隐含层 | 处理时间 | 泛化误差 |
|-----|----|-------------|-----------------|--------|--------|------|
| 1 | | 1 (traingd) | 1 (0.1) | 1 (5) | 12.95s | 0.92 |
| 2 | | 1 (traingd) | 2 ($1e^{-2}$) | 2 (10) | 380s | 0.54 |
| 3 | | 1 (traingd) | 3 ($1e^{-4}$) | 3 (20) | >30min | - |

| | | | | | |
|----|--------------|----------|--------|--------|------|
| 4 | 1 (traingd) | 4 (1e-6) | 4 (40) | >30min | - |
| 5 | 2 (trainscg) | 1 (0.1) | 2 (10) | 4.34s | 0.93 |
| 6 | 2 (trainscg) | 2 (1e-2) | 3 (20) | 5.19s | 0.18 |
| 7 | 2 (trainscg) | 3 (1e-4) | 4 (40) | 4.55s | 0.09 |
| 8 | 2 (trainscg) | 4 (1e-6) | 1 (5) | 5.76s | 0.19 |
| 9 | 3 (trainbr) | 1 (0.1) | 3 (20) | 4.80s | 0.79 |
| 10 | 3 (trainbr) | 2 (1e-2) | 4 (40) | 7.99s | 0.50 |
| 11 | 3 (trainbr) | 3 (1e-4) | 1 (5) | 4.70s | 0.05 |
| 12 | 3 (trainbr) | 4 (1e-6) | 2 (10) | 4.92s | 0.06 |
| 13 | 4 (trainlm) | 1 (0.1) | 4 (40) | 4.89s | 0.90 |
| 14 | 4 (trainlm) | 2 (1e-2) | 1 (5) | 4.41s | 0.48 |
| 15 | 4 (trainlm) | 3 (1e-4) | 2 (10) | 4.47s | 0.09 |
| 16 | 4 (trainlm) | 4 (1e-6) | 3 (20) | 5.66s | 0.08 |

从训练时间和泛化误差两个优化参数来看,学习算法可以选择 trainbr 或者 trainlm, 学习目标至少设为 1e-4, 隐含层神经元个数在 10~20 左右较优。

在完成 BP 模型参数优化后, 使用主元分析法进行诊断输入参数精简, 对多变量进行降维处理和信息提取。通过线性变换将原始数据变换为一组各维线性无关的表示, 用于提取数据的主要特征分量^[10]。主元矩阵对应着最大特征值的 k 个主元代表着系统的特征变化。最佳 K 值的选取通过主元矩阵的协方差矩阵的累计贡献率来获得^[11]。

$$CV_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i} \quad (2)$$

其中, $\lambda_i (i \in [1, n])$ 是协方差的非负特征值, 且 $\lambda_1 > \lambda_2 > \dots > \lambda_n > 0$ 。当累计贡献率超过 85% 所对应的 k 值即为较优值。经过处理后得出的特征值和累计贡献率如图 7、8 所示。




图 8 不同主元特征值变化

Fig.8 The eigenvalues change with different pivot elements




图 9 不同主元贡献率与累计贡献率

Fig.9 Different principal component contribution rates and cumulative contribution rates

从上图可知, $k=4$ 的时候, 累计贡献率 $CV_k=86.28\%$ 。网络输入神经元可以从原始数据对应的 18 个变成主元空间对应下的 4 个, 大大减少了输入神经元, 降低了内存的占用。

应用主元分析后的 BP 神经网络的训练结果如表 2 所示。

表 2 PCA 处理前后的神经网络训练结果

Table 2 Neural network training results before & after processing

| 学习 算法 | 学习 目标 | 隐含 层 | 处理时间 | | 泛化误差 | |
|-------------|----------|---------|-----------|-----------|-----------|-----------|
| | | | 主元 优化前 | 主元 优化前 | 主元 优化前 | 主元 优化前 |
| Trainl m | 1e-4 | 20 | 5.832 | 5.077 | 0.075 | 0.095 |
| | 1e-5 | | 6.317 | 5.140 | 0.1 | 0.09 |
| Trainl m | 1e-4 | 15 | 5.139 | 4.806 | 0.1 | 0.09 |
| | 1e-5 | | 5.352 | 4.773 | 0.1 | 0.09 |

| | | | | | | |
|---------|------------------|----|-------|-------|-------|-------|
| trainbr | 1e ⁻⁴ | 20 | 8.205 | 5.888 | 0.1 | 0.11 |
| | 1e ⁻⁵ | | 6.557 | 5.996 | 0.1 | 0.07 |
| trainbr | 1e ⁻⁴ | 15 | 5.239 | 5.162 | 0.1 | 0.09 |
| | 1e ⁻⁵ | | 6.177 | 5.217 | 0.085 | 0.065 |

应用主元调整后的 BP 神经网络降低了故障推理模型的运行时间, 泛化误差变化不明显, 在实时在线检测民机蒸发循环制冷系统时, 由于处理数据量大, 主元优化将发挥重要的作用。

4 结论

为建立民机蒸发循环制冷系统的故障诊断模型, 对系统 9 种典型故障进行了实验模拟, 在故障数据库基础上, 利用 BP 神经网络算法进行了故障诊断推理模型开发, 对存在或潜在的故障进行定位和判断, 获得了合理有效的故障推理模型, 模型准确率到达 90% 以上。

在此基础上, 对模型的参数进行优化, 提高了泛化准确率以及计算时间, 为在线诊断的及时性提供良好的保障。同时, 利用主元分析法对输入变量进行处理, 降低了输入变量的维度, 提高了计算速度。

参考文献:

- [1] 姜学鹏, 洪贝, 崔嘉, 等. 综合飞行器故障预测与健康管理系统研究[J]. 工程与技术, 2008, (5): 14-17.

(下转第 339 页)