

文章编号:0253-4339(2020)01-0147-07

doi:10.3969/j.issn.0253-4339.2020.01.147

基于改进主元分析方法的空调系统传感器故障检测和诊断研究

张爽爽 陈焕新 张弘韬 郭亚宾

(华中科技大学能源与动力工程学院 武汉 430074)

摘要 传感器在空调系统中主要起着监测和控制的作用,影响空调系统的正常运行,从而带来能耗增加等不良影响。本文提出了结合小波变换的数据优化,以及基于神经网络的故障诊断优化的改进主元分析方法,用于空调系统传感器故障检测和诊断研究。通过对比数据优化前后主元分析的结果,发现同样 0.850 0 累计贡献率原则上,采用小波变换去除噪声后,主元个数减少了两个,蒸发器进口温度传感器的固定偏差、漂移、精度下降等故障检测效果分别提升了 0.020 7、0.020 8、0.041 5,风量传感器固定偏差故障检测效果提升了 0.160 6。为了进一步找出故障源,在小波变换和主元分析的基础上,将求得的主元作为神经网络的输入,对 5 个传感器固定偏差故障进行测试,故障诊断结果分别为 0.766 7、0.866 7、0.900 0、1.000 0、1.000 0。

关键词 故障检测和诊断;主元分析;神经网络;小波去噪;空调系统

中图分类号:TB657.2; TU831.3; TP183

文献标识码:A

Sensor Fault Detection and Diagnosis of Air-conditioning System Based on Improved Principal Component Analysis Method

Zhang Shuangshuang Chen Huanxin Zhang Hongtao Guo Yabin

(School of Energy and Power Engineering, Huazhong University of Science and Technology, Wuhan, 430074, China)

Abstract Sensors mainly play monitoring and controlling roles in air-conditioning systems and affect their normal operation, thereby causing adverse effects such as increased energy consumption if there are faults in sensors. In this study, an improved principal component analysis method combining wavelet transform data optimization and neural network-based fault diagnosis optimization is proposed for the sensor fault detection and diagnosis in an air-conditioning system. By comparing the results of principal component analysis before the data optimization and the results of the principal component analysis after the data optimization, it was found that in the principle of the same 0.850 0 cumulative contribution rate after the wavelet transform used to remove noise, the number of principal components was reduced by two; the detection effect was improved by 0.020 7, 0.020 8, and 0.041 5 respectively; and the effect of the airflow sensor fixed deviation failure detection was improved by 0.160 6. To find the source of the fault, the principal component analysis was used as the input of the neural network to test five sensor fixed deviation faults based on the wavelet transform and principal component analysis. The fault diagnosis results were 0.766 7, 0.866 7, 0.900 0, 1.000 0, and 1.000 0, respectively.

Keywords fault detection and diagnosis; principal component analysis; neural network; wavelet denoising; air-conditioning system

现代建筑中空调系统传感器数量巨大且承担的功能各不相同,一旦发生故障,正常的人力很难及时检测到,进而影响空调系统的正常运行,造成巨大的能源浪费和财产损失^[1]。因此,进行空调系统故障检测和诊断(fault detection and diagnosis, FDD)研究具有非常重要的价值及意义。

现有的传感器故障诊断的方法可以分为基于解析模型的方法和数据驱动的方法^[2]。基于模型的方

法,首先在了解系统机理的条件下建立精确的模型,正是由于这个前提,导致该方法在空调系统领域难以实行。基于数据驱动的故障诊断方法在近几年成为了研究热点^[3]。主元分析(principal component analysis, PCA)是常用的多元统计分析方法之一,通过对原始变量空间进行分解变换,根据系统相关性提取新的变量,降低原始数据维度,可以达到良好的故障检测与诊断效果^[1, 4-6]。兰丽丽^[7]通过实际测试证明基于

PCA 检测传感器故障的方法是正确有效的。仇韬等^[8]提出多模型 PCA 算法在非线性较为严重的电厂热工过程可以进行精确的传感器故障检测。Du Zhimin 等^[9]通过测试发现,无论监测型传感器还是控制型故障,PCA 模型均能给出正确的可靠性等级。尽管主元分析模型拥有良好的故障检测性能,但在故障源的诊断方面可能会发生误判^[10],误判会消耗大量不必要的人力、物力、财力,由于神经网络在故障诊断领域体现出的独特优势,所以引入神经网络进行故障诊断。

神经网络具有很强的鲁棒性和容错性以及自适应性,并且可以实现非线性映射、分类识别等功能,可作为分类器用于故障诊断中^[11]。神经网络计算速度和其结构有很大关系,输入节点越少,计算速度越快。因此,结合 PCA 和神经网络的优点,利用 PCA 进行降维,可大大节省故障诊断时间^[12-14]。

基于数据驱动的方法对于原始数据的数量和质量要求较高,并且由于空调系统包含变量较多,神经网络结构一般比较复杂,而言运行时间相对较长。利用小波优化后的数据去除了噪声,通过 PCA 得到的主元数量进一步减少,又包含原始变量的绝大部分信息^[3],因此,将其作为神经网络的输入,可以简化网络结构,减少运行时间^[11]。并且 Du Zhimin 等^[15]测试发现小波神经网络可以成功诊断传感器固定和漂移偏差。石书彪等^[16]发现小波去噪后可以提高神经网络整体检测故障效率。

本文以风冷式全空气空调系统为研究对象,通过能量守恒筛选出有效变量,在系统正常运行时收集传感器数据,提出采用小波变换去除数据的噪声,并利用 PCA 进行故障检测,引入神经网络实现故障诊断。

1 数据采集及模型建立

1.1 原始数据的采集

实际上,空调系统的 FDD 分析是利用空调监测系统运行时采集到的一系列数据进行数据分析的过程。图 1 所示为风冷式全空气空调系统制冷循环原理。该系统主要由压缩机、回油器、冷凝器、过滤器、膨胀阀、双效蒸发器、风机等基本部件构成。实际机组中,为了提高运行的经济性和保证操作管理工作的安全性,增加了一些辅助设备,如电磁阀、止回阀、压力表、温度计、安全阀、液位计和一些自动控制及保护装置,如防冻保护、防热保护、高低压保护。

系统设置了压力传感器、温度传感器、流量传感器以及功率传感器,监测系统的运行状态,每 5 s 收

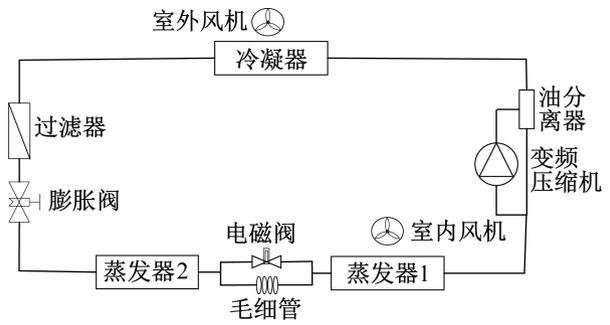


图 1 风冷式全空气空调系统制冷循环原理

Fig.1 Principle of air-cooled air conditioning system refrigeration cycle

集一次数据。通过压缩、冷凝、节流和蒸发 4 个过程热平衡定理以及能量守恒原则能量^[17]可知,空调系统的能量守恒涉及到 13 个重要的测量值,分别为压缩机功率 W 、冷凝压力 p_c 、蒸发压力 p_e 、冷凝器进口温度 $T_{c, in}$ 、冷凝器出口温度 $T_{c, out}$ 、冷凝器侧的进风温度 T_{ia} 、冷凝器侧的出风温度 T_{oa} 、蒸发器进口温度 $T_{e, in}$ 、蒸发器出口温度 $T_{e, out}$ 、回风温度 T_{ra} 、送风温度 T_{sa} 、制冷剂质量流量 M_{ref} 、风量 V_a 。因此从所记录传感器测量值中选择这 13 个传感器测量值,作为原始数据进行空调系统传感器故障检测和诊断。

1.2 构建 PCA 神经网络模型

本文构建出小波变换数据优化、PCA 故障检测、神经网络故障诊断模型。空调系统数据处于动态变化中,传感器在收集数据过程中难免会有部分噪声的存在,因此采用小波变换对数据进行优化,输出高质量的数据为故障检测诊断模型做准备。在该模型中,PCA 有两个重要作用:其一,由于该模型对变量间的相关性高度敏感,利用 SPE 统计量可以迅速准确的检测故障;其二,PCA 将原始高维数据变换为低维数据,作为神经网络故障诊断模型的输入。PCA 模型拥有良好的故障检测性能,但在故障源的诊断方面可能会发生误判,由于神经网络在故障诊断领域体现出的独特优势,所以引入了神经网络进行故障诊断。神经网络故障诊断模型结构复杂度与运算量和模型的输入节点有很大的联系,减少输入节点数目可以帮助模型更为高效的计算。三者保持着各自的优点的同时互相弥补不足,改进 PCA 方法同时具备故障检测和诊断效率高、运行时间快的优点,是一种良好的故障检测和诊断方法。

图 2 所示为基于改进 PCA 方法的空调系统传感器故障检测和诊断流程。

故障检测和诊断流程主要包括 4 个过程:

1) 数据的收集和优化过程。首先收集机组历史

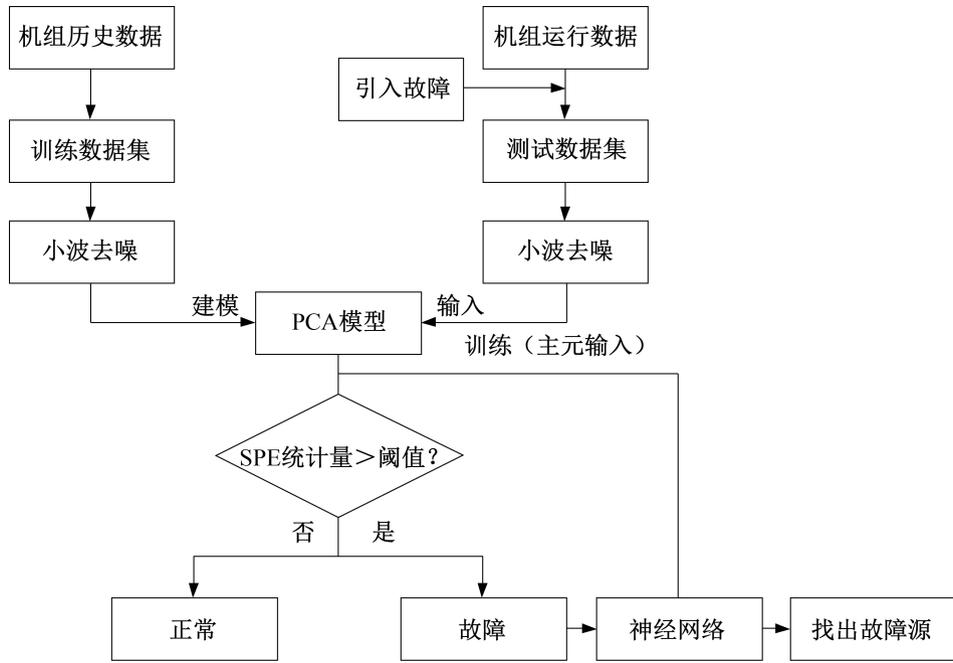


图 2 基于改进 PCA 方法的空调系统传感器故障检测和诊断流程

Fig.2 The flow of sensor fault detection and diagnosis of air conditioning system based on improved PCA method

数据和运行数据,得到的信号使用 dB3 小波进行 3 层分解,对其高频部分进行阈值处理,去除信号中的噪声,尽可能还原真实信号,得到优化后的数据;

2) PCA 建模过程。利用优化后的正常稳定运行工况下的历史数据,将其分为两部分,一部分作为训练数据训练 PCA 模型,求出主元,并确定平方预测误差 (squared prediction error, SPE) 的阈值;

3) 故障检测过程。将去噪后的机组运行数据输入到 PCA 模型中,分析其 SPE 统计量,当某一传感器发生故障时, SPE 统计量就会增大,若 SPE 统计量超过可控域,则可认为有故障发生,进入下一环节;否则,认为系统正常运行,得到诊断结果;

4) 故障诊断过程。首先利用一组可能发生的所有故障样本转化为主元对网络进行训练,以确定网络的结构(中间层的传递函数和神经元数目)和参数(神经元之间的连接权值和阈值)。确定有故障发生后,将机组运行数据转化为主元继续输入到训练好的神经网络模型中,识别故障源,得到诊断结果。

2 小波去噪前后机组数据分析

2.1 基于 PCA 的机组数据分析

基于 PCA 的故障检测与诊断方法完全基于系统运行过程中传感器的测量数据,从统计角度上建立系统模型,直接用数据的变化情况来发现和解决问题,不需要建立复杂的解析模型,进而解决了难以直接建立空调系统的解析模型的难题。PCA 分为训练和测

试两个部分,训练集一般为正常稳定运行的机组数据,测试集一般为故障数据。由于故障数据可能耗费大量的时间以及金钱成本,所以本实验中测试集采用人为引入故障。因此,从收集的稳定运行数据中选取 443 个样本并将其分为两部分,前 250 个样本用于模型的训练,称为训练集;后 193 个样本人为引入故障,称为测试集。

PCA 训练过程分为 9 个步骤:1) 输入原始训练数据 X_0 ; 2) 对原始数据进行零平均值与单位方差化; 3) 求得协方差矩阵; 4) 运用协方差矩阵进行主成分分析,得到特征值向量; 5) 计算贡献率及累计贡献率,按照累计贡献率 ≥ 0.8500 的标准,选取主成分的个数 k ; 6) 计算荷载矩阵, C 矩阵; 7) 根据 0.9500 的置信限计算得到 SPE 统计量的阈值; 8) 计算训练矩阵自检测效率; 9) 计算 SPE 统计量的均值和方差。

通过上述步骤实现 PCA 算法,运行之后可以得出训练矩阵的 13 个特征值、贡献率以及累计贡献率,如表 1 所示。

在建立 PCA 模型的过程中,需要确定一个关键参数主元个数 k ,主元个数选取的是否合理直接决定 PCA 模型进行故障检测的性能。选取原则是希望这 k 个主元能够尽可能包括原始变量的信息。一般采用累计贡献率的准则来确定主元个数。第 k 个主元贡献率是指该主元所对应的特征值除以所有特征值之和,前 k 个主元累计贡献率是指前 k 个主元所对应的特征值之和除以所有特征值之和。由表 1 可

表 1 基于 PCA 模型训练矩阵的特征值、贡献率以及
累计贡献率

Tab.1 The eigenvalues, contribution rates, and cumulative
contribution rates of the training matrix based on
the PCA model

第 N 个主元	特征值	贡献率	累计贡献率
1	4.610 6	0.354 7	0.354 7
2	2.155 1	0.165 8	0.520 4
3	1.478 2	0.113 7	0.634 1
4	1.053 9	0.081 1	0.715 2
5	0.736 5	0.056 7	0.771 9
6	0.672 1	0.051 7	0.823 6
7	0.583 9	0.044 9	0.868 5
8	0.477 6	0.036 7	0.905 2
9	0.370 8	0.028 5	0.933 7
10	0.296 9	0.022 8	0.956 6
11	0.243 0	0.018 7	0.975 3
12	0.240 2	0.018 5	0.993 8
13	0.081 2	0.006 2	1.000 0

知,主元 N 所代表的数字越小,对应的特征值越大,贡献率也越高。从第 8 个主元开始,所对应的贡献率已经低至 0.036 7。说明第 8 个主元包含的信息很

少,可以忽略不计。根据累计贡献率 0.850 0 的标准,选取主元个数 k 为 7,前 7 个主元的累计贡献率达到 0.868 5。

2.2 基于 WPCA 的机组数据分析

在常规主元分析的基础上,提出了结合小波去噪的测量数据优化方法,读取数据后,先利用小波变化去除信号中的噪声,从而提高传感器故障检测效率。为了便于对比,将基于常规的主元分析称为 NPCA (normal principal component analysis),结合小波去噪的主元分析方法称为 WPCA (principal component analysis combined with wavelet transfer)。

本文所研究的数据用一个 443 行 13 列的矩阵表示 13 个变量,443 个样本,使用小波变换按列进行除噪,提取机组数据中的有用部分,得到机组数据在小波去噪后分析数据。采用 NPCA 和 WPCA 方法的特征值、贡献率以及累计贡献率分别列在表 2。由表 2 可知,WPCA 方法第一主元的贡献率已经达到了 0.403 0,远大于 NPCA 方法第一主元的贡献率 0.354 7,说明 WPCA 方法第一主元所包含的原始信息更多。仍然根据累计贡献率 0.850 0 的标准,WPCA 方法在主元个数为 5 时,累计贡献率为 0.852 9,可以确定 WPCA 方法的主元个数为 5,相比于 NPCA 方法的主元个数减少了两个主元,在包含了原数据主要信息的同时,更好的实现了降维的目的。

表 2 NPCA 和 WPCA 方法的特征值、贡献率以及累计贡献率对比

Tab.2 Comparison of eigenvalues, contribution rates, and cumulative contribution rates of NPCA and WPCA

第 N 个主元	NPCA			WPCA		
	特征值	贡献率	累计贡献率	特征值	贡献率	累计贡献率
1	4.610 6	0.354 7	0.354 7	5.238 5	0.403 0	0.403 0
2	2.155 1	0.165 8	0.520 4	2.473 3	0.190 3	0.593 2
3	1.478 2	0.113 7	0.634 1	1.626 2	0.125 1	0.718 3
4	1.053 9	0.081 1	0.715 2	1.101 2	0.084 7	0.803 0
5	0.736 5	0.056 7	0.771 9	0.649 1	0.049 9	0.852 9
6	0.672 1	0.051 7	0.823 6	0.550 9	0.042 4	0.895 3
7	0.583 9	0.044 9	0.868 5	0.410 9	0.031 6	0.926 9
8	0.477 6	0.036 7	0.905 2	0.278 3	0.021 4	0.948 3
9	0.370 8	0.028 5	0.933 7	0.225 3	0.017 3	0.965 7
10	0.296 9	0.022 8	0.956 6	0.186 6	0.014 4	0.980 0
11	0.243 0	0.018 7	0.975 3	0.127 6	0.009 8	0.989 8
12	0.240 2	0.018 5	0.993 8	0.094 3	0.007 3	0.997 1
13	0.081 2	0.006 2	1.000 0	0.037 9	0.002 9	1.000 0

3 故障检测和诊断结果

3.1 故障检测结果

蒸发器进口温度传感器引入+0.2℃的固定偏差故障时,利用已建立好的 PCA 模型进行故障检测。图 3 所示为蒸发器进口温度传感器引入+0.2℃固定偏差故障时,SPE 统计量变化曲线。第 251 个样本点为故障引入点,原始数据在 250 个样本点之前,SPE 统计量虽然也有波动,但是大部分都在阈值以下,位于控制限内,可以认为数据正常,即传感器无故障。从 251 个样本点开始,SPE 统计量急剧增加,且波动剧烈,大部分在阈值以上,说明传感器可能发生了故障,故障检测效率为 0.943 0。原始数据经过小波去噪后,SPE 统计量波动不完全一样,从故障引入点开始,SPE 统计量明显增大,并且 0.963 7 的故障点的 SPE 统计量都大于阈值,即故障检测效率为 0.963 7。

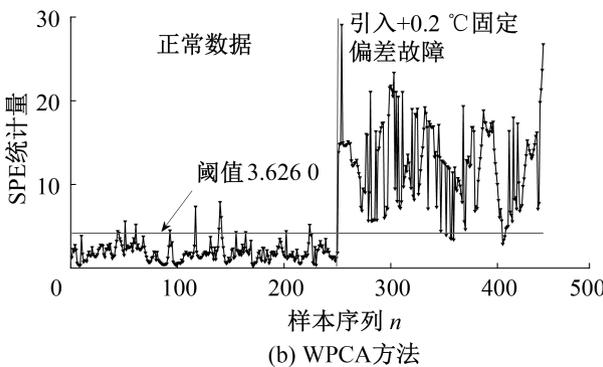
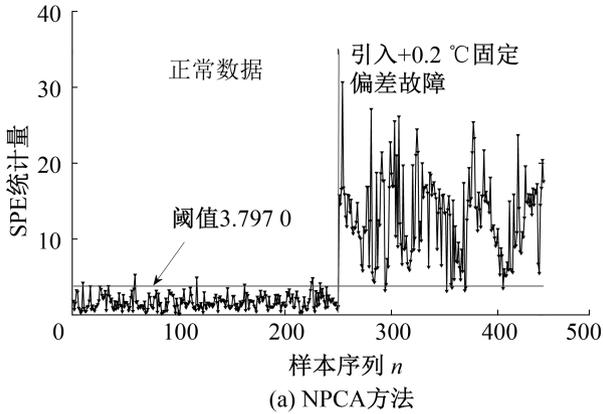


图 3 温度传感器引入+0.2℃固定偏差故障时, SPE 统计量变化

Fig.3 Change of SPE statistics in +0.2℃ fixed deviation of temperature sensor

图 4 所示为风量传感器引入+1%的固定偏差故障时 SPE 统计量变化曲线,第 251 个样本为故障引入点,利用已建立好的 PCA 模型进行故障检测。从故障引入样本开始,SPE 统计量大部分高出阈值,使用 PCA 模型进行故障检测时效率为 0.839 4,使用

WPCA 模型进行故障检测时,从故障引入点开始,SPE 统计量急剧增加至阈值以上,并且所有故障点都可以被检测出来,故障检测效率为 1.000 0,WPCA 方法 SPE 统计量升高的更多。证明 PCA 模型对于风量传感器具有良好的故障检测功能。

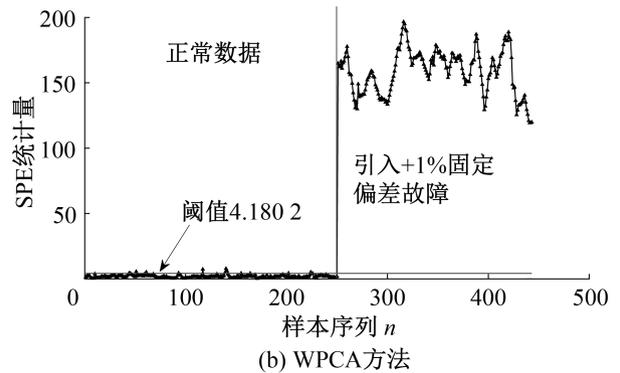
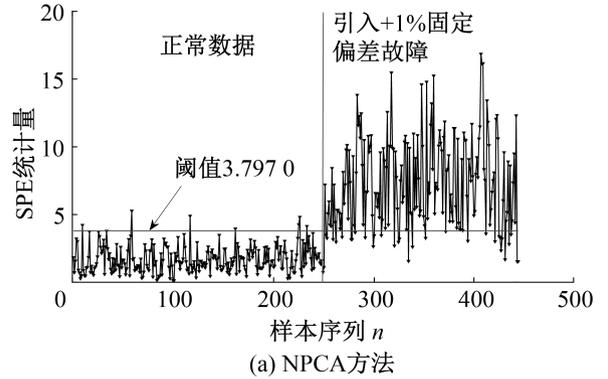


图 4 风量传感器引入+1%固定偏差故障时, SPE 统计量变化

Fig.4 Change of SPE statistics in +1% fixed deviation of air volume sensor

表 3 所示为 NPCA 和 WPCA 方法故障检测效率对比。由表 3 可知,对于固定偏差,即使很小的故障 PCA 方法也很容易检测出来,并且小波去噪后故障检测效率升高。对于漂移和精度下降,NPCA 的故障检测效率也分别达到了 0.963 7 和 0.937 8,而且进行了小波去噪后,故障检测效率均有明显上升,因此 WPCA 方法的故障检测效率优于 NPCA 方法的检测效率。

3.2 故障诊断结果

由于故障类型过多(13 个传感器可能发生不同类型的故障),本文对部分温度传感器和风量传感器发生故障时神经网络的故障诊断效率进行了研究。用于验证的传感器故障有冷凝器进口温度 $T_{c, out} + 0.5℃$ 固定偏差故障,冷凝器侧的进风温度 $T_{ia} + 0.5℃$ 固定偏差故障,蒸发器进口温度 $T_{c, in} + 0.2℃$ 固定偏差故障,回风温度 $T_{ra} + 0.5℃$ 固定偏差故障,以及风量 $M_a + 5%$ 固定偏差故障,分别标记为故障类

型 5、7、9、11、13。5 种故障类型选取的训练组数全都为 60 组,验证神经网络故障诊断能力 5 种故障类型

的测试组分别为 30、30、30、30、23 组。取较好的一次诊断结果,如图 5 所示。

表 3 NPCA 和 WPCA 方法故障检测效率对比
Tab.3 Comparison of NPCA and WPCA methods for fault detection efficiency

测量参数	故障类型	数值	故障检测效率		
			NPCA 方法	WPCA 方法	提升效率
$T_{e, in}$	固定偏差	+0.2 °C	0.943 0	0.963 7	0.020 7
		+0.5 °C	100	100	
$T_{e, in}$	漂移	3 °C/193 个样本	0.963 7	0.984 5	0.020 8
$T_{e, in}$	精度下降	方差为 2	0.937 8	0.979 3	0.041 5
M_a	固定偏差	1%	0.839 4	1.000 0	0.160 6

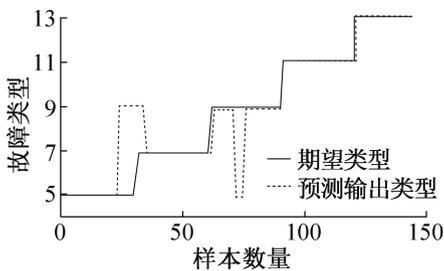


图 5 WPCA 神经网络方法故障诊断结果

Fig.5 Neural network method fault diagnosis results with WPCA

表 4 所示为 WPCA 神经网络模型故障诊断效率。

表 4 WPCA 神经网络模型故障诊断效率

Tab.4 Neural network model fault diagnosis efficiency

故障类型	传感器测量参数	故障类型	固定偏差	WPCA 故障诊断效率
5	$T_{c, out}$	固定偏差	+0.5 °C	0.766 7
7	T_{ia}	固定偏差	+0.5 °C	0.866 7
9	$T_{e, in}$	固定偏差	+0.2 °C	0.900 0
			+0.5 °C	0.666 7
11	T_{ra}	固定偏差	+0.5 °C	1.000 0
13	M_a	固定偏差	+5%	1.000 0

由表 4 可知,不同温度传感器发生大小相等的固定偏差时,故障诊断效率并不相同,同样引入+0.5 °C 固定偏差,改进主元分析方法对冷凝器进口温度传感器的故障诊断效率只有 0.766 7,对回风温度传感器的故障诊断效率却高达 1.000 0。蒸发器进口温度传感器分别引入+0.2 °C 和+0.5 °C 的固定偏差故障,故障诊断效率分别为 0.900 0 和 0.666 7,说明故障大小和故障诊断效率并无必然的因果关系,这就为该方法在早期故障发生程度较小时的故障诊断应用提供了条件。对于风量传感器引入+5%的固定偏差,改进主元分析方法的故障诊断效率达到了 1.000 0,说明

该方法不仅可以诊断温度传感器故障,只要经过训练,对于其他类型的传感器,如风量传感器、液位传感器等,也有良好的故障诊断功能。

4 结论

本文以风冷式全空气系统为研究对象,在系统正常运行时收集到一系列数据,通过能量守恒定律筛选出 13 个传感器变量,采用小波变换去除原始数据中的噪声,然后将小波优化后的数据分为两部分,其中一部分直接用作训练集,另一部分通过人工加入故障作为测试集。将训练集输入 PCA 模型进行故障检测,如检测出故障发生则继续将主元输入至神经网络模型中进行故障诊断,从而找出故障源。经过实验验证,该方法具有良好的故障检测和诊断功能,得到如下结论:

1) 通过采集正在连续运行的空调机组数据,建立了风冷式全空气系统的能耗模型,得到其中的关键传感器变量。

2) 通过对比小波去噪前后主元分析结果,发现原始数据经过小波变换后,去除了噪声和冗余信息,所以同样 0.850 0 贡献率的原则下,小波去噪后的主元分析法选取的主元数目较传统的主元分析法减少了两个,蒸发器进口温度传感器的固定偏差、漂移、精度下降等故障检测效果分别提升了 0.020 7、0.020 8、0.041 5,风量传感器固定偏差故障检测效果提升了 0.160 6。同时,由于主元数量减少,所以使用主元作为输入的神经网络结构相对来说变得简单,从而缩短故障诊断所需时间,为空调系统传感器实时连续检测和诊断提供了基础条件。

3) 针对主元分析方法在故障诊断领域的不足,引入神经网络作为分类器进行故障诊断优化,提高诊断结果准确性。通过 BP 神经网络程序仿真实验验

证,测试 5 个传感器固定偏差故障的诊断结果分别为 0.766 7、0.866 7、0.900 0、1.000 0、1.000 0。测试的传感器类型不同,引入误差不同,进一步证明了该模型对于不同类型不同大小的误差均表现出良好的诊断性能。

参考文献

- [1] 禹法文,陈焕新,李绍斌,等. 基于主元分析法的多联机系统压缩机排气温度传感器故障检测与诊断[J]. 制冷技术, 2017, 37(4): 29-33. (YU Fawen, CHEN Huanxin, LI Shaobin, et al. Sensor fault detection and diagnosis for compressor exhaust temperature of variable refrigerant volume system based on principal component analysis [J]. Chinese Journal of Refrigeration Technology, 2017, 37(4): 29-33.)
- [2] 周东华,李钢,李元. 数据驱动的工业过程故障诊断技术: 基于主元分析与偏最小二乘的方法[M]. 北京: 科学出版社, 2011. (ZHOU Donghua, LI Gang, LI Yuan. Data-driven industrial process fault diagnosis technology: a method based on principal component analysis and partial least squares[M]. Beijing: Science Press, 2011.)
- [3] 胡云鹏. 基于主元分析的冷水机组传感器故障检测效率研究[D]. 武汉: 华中科技大学, 2013. (HU Yunpeng. A study of sensor fault detection in chiller based on PCA method[D]. Wuhan: Huazhong University of Science and Technology, 2013.)
- [4] WANG Shengwei, CUI Jingtian. Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method[J]. Applied Energy, 2005, 82(3): 197-213.)
- [5] XU Xinhua, XIAO Fu, WANG Shengwei. Enhanced chiller sensor fault detection, diagnosis and estimation using wavelet analysis and principal component analysis methods[J]. Applied Thermal Engineering, 2008, 28(2): 226-237.)
- [6] 张弘韬,陈焕新,李冠男,等. 主元分析用于多联式空调系统传感器故障检测和诊断[J]. 制冷学报, 2017, 38(3): 76-81. (ZHANG Hongtao, CHEN Huanxin, LI Guannan, et al. Sensor fault detection and diagnosis for variable refrigerant flow air conditioning system based on principal component analysis [J]. Journal of Refrigeration, 2017, 38(3): 76-81.)
- [7] 兰丽丽. 基于 PCA 的空气源热泵空调系统故障诊断[D]. 长沙: 湖南大学, 2008. (LAN Lili. Fault detection diagnosis in air-source heat pump air-conditioning system using PCA method[D]. Changsha: Hunan University, 2008.)
- [8] 仇韬,张清峰,丁艳军,等. PCA 在非线性系统传感器故障检测和重构中的应用[J]. 清华大学学报(自然科学版), 2006, 46(5): 708-711. (QIU Tao, ZHANG Qingfeng, DING Yanjun, et al. Nonlinear sensor fault detection and data rebuilding based on principle component analysis[J]. Journal of Tsinghua University (Science and Technology), 2006, 46(5): 708-711.)
- [9] DU Zhimin, CHEN Ling, JIN Xinqiao. Data-driven based reliability evaluation for measurements of sensors in a vapor compression system[J]. Energy, 2017, 122:237.
- [10] 韩同瑞. 基于主元分析法的工业锅炉故障诊断的研究[D]. 大连: 大连海事大学, 2012. (HAN Tongrui. Research on fault diagnosis of industrial boiler based on principal component analysis[D]. Dalian: Dalian Maritime University, 2012.)
- [11] DU Zhimin, JIN Xinqiao, YANG Yunyu. Fault diagnosis for temperature, flow rate and pressure sensors in VAV systems using wavelet neural network [J]. Applied Energy, 2009, 86(9): 1624-1631.)
- [12] 么之欣. 基于 PCA 神经网络的电路电子整流装置故障诊断方法[J]. 硅谷, 2008(15): 17-18. (YAO Zhixin. Circuit electronic rectifier device fault diagnosis method based on PCA neural network [J]. Silicon Valley, 2008(15): 17-18.)
- [13] 杨金宝,张昌宏,陈平. 基于改进 BP 神经网络的网络故障诊断研究[J]. 计算机与数字工程, 2012, 40(2): 65-67. (YANG Jinbao, ZHANG Changhong, CHEN Ping. Network fault diagnosis based on improved bp neural network [J]. Computer and Digital Engineering, 2012, 40(2): 65-67.)
- [14] 朱兴统,熊建斌. 基于 PCA 和 BP 神经网络的故障诊断仿真系统[J]. 自动化与仪器仪表, 2015(12): 47-48, 51. (ZHU Xingtong, XIONG Jianbin. Fault diagnosis simulation system based on PCA and BP neural network [J]. Automation & Instrumentation, 2015(12): 47-48, 51.)
- [15] DU Zhimin, JIN Xinqiao, YANG Yunyu. Wavelet neural network-based fault diagnosis in air-handling units [J]. HVAC & R Research, 2008, 14(6): 959-973.)
- [16] 石书彪,陈焕新,李冠男,等. 基于小波去噪和神经网络的冷水机组故障诊断[J]. 制冷学报, 2016, 37(1): 12-17. (SHI Shubiao, CHEN Huanxin, LI Guannan, et al. Fault diagnosis of chillers based on neural network and wavelet denoising [J]. Journal of Refrigeration, 2016, 37(1): 12-17.)
- [17] 胡云鹏,陈焕新,周诚,等. 基于主元分析法的冷水机组传感器故障检测效率分析[J]. 化工学报, 2012, 63(增刊 2): 85-88. (HU Yunpeng, CHEN Huanxin, ZHOU Cheng, et al. Analysis of sensor fault detection in chiller based on PCA method [J]. CIESC Journal, 2012, 63(Suppl. 2): 85-88.)

通信作者简介

陈焕新,男,教授,华中科技大学能源与动力工程学院,(027) 87558330,E-mail:chenhuanxin@tsinghua.org.cn.研究方向:制冷空调系统测控技术与计算机仿真。

About the corresponding author

Chen Huanxin, male, professor, School of Energy and Power Engineering, Huazhong University of Science and Technology, +86 27-87558330, E-mail: chenhuanxin@tsinghua.org.cn. Research fields: measure and control technique and computer simulation of refrigeration of air-conditioning system.