高技术通讯 2023 年 第33 卷 第7 期:772-780

doi:10.3772/j.issn.1002-0470.2023.07.011

基于数据-机理联合驱动的制冷空调系统故障特征提取方法①

孙 哲②* 金华强*** 李 康* 顾江萍*** 黄跃进* 沈 希③***

(* 浙江工业大学机械工程学院 杭州 310014)

(** 浙江农林大学光机电工程学院 杭州 311300)

(*** 浙江工业大学教育科学与技术学院 杭州 310014)

摘 要 制冷空调系统故障特征提取是系统故障诊断的基础。现有研究常利用端到端的黑箱模型实现自主特征提取,获得的特征不具备物理解析,无法保证其全局应用的可靠性。针对制冷空调系统展开具有明确物理意义的特征提取研究对实现可靠可信故障诊断具有重要意义。本文提出一种数据-机理联合驱动的故障特征提取方法,针对动态运行数据复杂多变特性,构建制冷系统基准模型和偏离特性表征策略,实现故障偏离特征的准确提取,并结合热力学机理分析对其进行理论解释。利用 ASHRAE RP-1043 数据集进行实验验证,获得 6 类典型故障特征并构建偏离特征矢量表,为故障诊断提供理论基础。

关键词 数据-机理联合驱动; 故障特征提取; 制冷空调系统; 深度学习

0 引 言

为应对世界能源紧缺与碳排放问题,我国提出“3060”双碳计划,各行各业纷纷制定本领域的战略方针[1]。制冷空调系统能耗是建筑能耗的重要组成,约占社会总能耗的 20%[2-3]。由于制冷空调系统结构复杂且运行环境较差,长期使用中不可避免地发生各类故障。制冷空调系统故障种类繁多,可以分为突变故障和渐变故障 2 大类,其中以热力故障为主的渐变故障具有隐蔽性高、对性能影响较大的特点,是系统能耗增加的重要因素。相关研究表明,制冷空调系统发生热力故障会造成 15% ~20% 的能耗增加[4]。

为避免热力故障发生造成系统能耗增加,大量学者针对智能故障诊断方法展开研究[5-9],而热力故障的特征提取是故障诊断的基础。随着近年来深度学习技术的兴起,故障诊断常利用端到端的黑箱模型实现,特征提取在黑箱模型内部自主实现[10-12]。也有一些学者利用数据挖掘算法实现故障特征自适应提取[13]。但上述 2 种提取手段获得的特征均为抽象特征,很难对其进行物理层面解释,使得基于上述特征实现的故障诊断缺乏物理背景,无法保证全局范围的可靠可信。通过对系统参数的偏离特征提取得到的知识具有明确的物理背景,基于此特征实现故障诊断可以更好地保证方法的可靠可信程度。已有研究对制冷空调系统故障偏离特性进行研究。文献[14]对制冷系统故障分类及变化征兆进行了理论分析。文献[15]从热力循环角度对制冷系统故障的特性进行了定性分析。上述 2 项研究基于热力学机理分析,从循环机理角度给出了制冷空调系统故障状态下参数变化的定性规律。文献[16]通过自主搭建制冷空调系统,在恒定控制条件下通过不断加深故障程度的方式研究了性能参数变化特性。文献[17]通过自主搭建变流量空调系统获取不同故障状态的运行参数,并从数据分析的角度阐

① 浙江省自然科学基金(LQ23E060006)和浙江省重点研发计划(2020C04010)资助项目。

② 男,1989 年生,博士;研究方向:能源热力系统大数据分析与智能化运维;E-mail: sunzhe91@zjut.edu.cn。

③ 通信作者,E-mail: sx@zjut.edu.cn。

(收稿日期:2021-11-04)

述了故障系统参数的变化规律。文献[18]通过对振动信号频域空间的分析,研究了小型全封闭压缩机典型故障特性。上述研究属于实验验证类型,通过搭建实验制冷系统或仿真系统,在恒定工况和恒定环境的条件下改变系统故障状态,分析系统参数的变化规律。由于制冷空调系统的复杂性,基于热力学分析的故障特性属于定性结论,无法准确定量描述,因此难以直接用于故障诊断。而实验系统得到的结论只适用于该系统本身,当诊断目标更换后无法直接应用。因此,必须利用目标系统自身动态数据进行准确的故障特征提取,才能更好地支撑故障诊断。

通过动态运行数据进行故障特征提取存在一个明显的难点,即数据自身波动大,故障状态的参数变化量难以计算。为计算出故障状态参数的偏离量,必须准确得到健康状态的基准值,即实现制冷空调系统的准确建模。制冷空调系统属于典型的强非线性系统,准确建模十分困难。随着数据驱动技术的飞速发展,利用深度神经网络实现对强非线性系统的拟合成为可能。本文利用深度神经网络构建制冷空调系统基准模型,并以此作为基准计算故障状态下的参数偏离值,实现基于动态运行数据的故障特征准确提取。

由于深度神经网络的训练算法基于随机梯度下降算法,使得模型的优化方向存在一定的不确定性。同时,完全的黑箱模型缺乏知识解析,使得提取的故障特征无法满足可信可靠的需求。文献[19]指出"建立新的可解释和鲁棒的 AI(artificial intelligence)理论与方法,需要将数据驱动和知识驱动范式结合起来,是发展 AI 的必经之路"。本文依据这一指导思想,充分结合数据和机理2种方法的优势,提出一种数据-机理联合驱动的制冷空调系统故障特征提取方法,通过数据驱动对机理分析的定性结论进行完善与补充,同时利用机理分析的定性结论来约束数据驱动方法,避免数据集和数据驱动算法自身误差对结论带来不良影响。相比现有研究,本文方法得到的故障特征更加准确可信。该方法不仅适用于制冷空调系统热力故障特征提取,同时可以应用于其他热力系统的故障特征提取。

1　特征提取方法

1.1　数据-机理联合驱动模式

制冷空调系统属于典型的强非线性系统,精准的故障机理定量分析难以实现,只能以定性的方式实现故障特性描述,无法满足故障诊断等问题的需求。通过实地采集或模拟实验的方式可以获取不同故障状态的系统运行数据,利用数据分析方法提取系统故障特征是一种有效途径。然而,现有数据分析方法多数建立在统计学基础上,存在2个缺陷:(1)对数据有效信息的提取和挖掘不充分,得到的结论不够精确;(2)无法有效解决数据和算法自身不确定因素带来的影响,得到的结论不够可信。特别是针对复杂系统的动态运行数据而言,有效信息提取的难度更大。

为解决上述问题,本文提出一种数据和机理的联合分析模式,包括2个部分:(1)针对制冷空调系统,建立一种高效的数据驱动故障特性表征方法,相比于现有数据分析方法,对故障规律表征更加清晰准确;(2)通过定性机理分析对数据驱动结论进行修正和解释,使得所有结论具有明确的物理意义。

联合分析方法的具体路线(见图1),通过数据分析与物理背景阐释相结合的方法,即可以充分准确地得到制冷空调系统故障状态参数的变化规律,又可以保证所得规律在物理背景下具备可信性。

1.2　制冷空调系统基准建模方法

制冷空调系统故障状态的表现是热力参数的定向偏离,不同系统间同一类故障的偏离规律是一致的,其差异在于偏离幅值不同。为探明各类故障的热力参数偏离规律,最为有效的方法是获取系统健康状态下热力参数的理想值,然后通过做差的方式即可得到偏离量。然而,制冷空调系统具有大滞后、强耦合的特点,热力参数受到环境、工况、负载等诸多因素影响,各因素之间具有强烈的非线性关系,故如何根据实际环境和工况等因素计算出健康系统热力参数的理想值是一个难题。

以深度学习为代表的数据驱动算法在复杂非线性系统拟合方面具有显著优势,不依赖人为知识即自主建立参数间映射关系。文献[8]提出一种融合

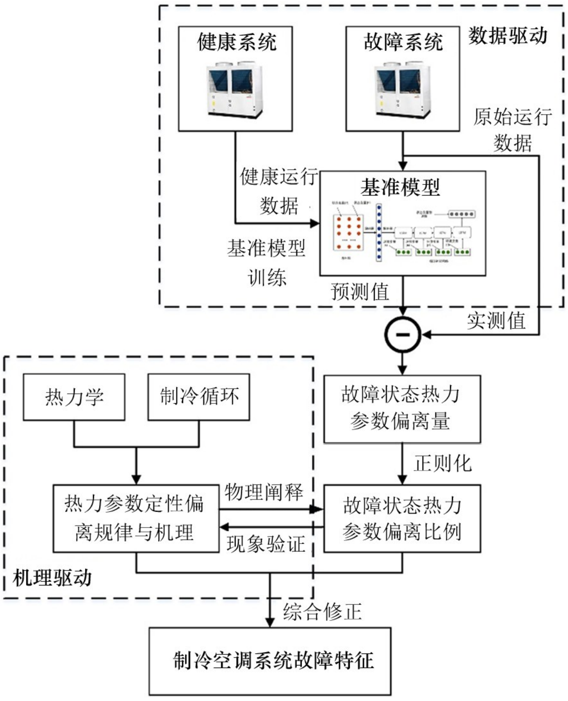

图 1　数据-机理联合驱动模式示意图

卷积网络、编-解码器和循环神经网络的深度模型，用于解决多维时序建模问题。本文利用该模型作为制冷空调系统基准模型，将当前环境参数和控制参数作为输入变量，预测对应的热力参数值。因为基准模型利用健康系统运行数据训练，因此预测的热力参数值属于健康系统的理想值。

基准模型结构如图 2 所示，模型的输入为制冷空调系统的外界自变参数，包括环境参数、控制参数、负载参数，例如环境温度、压机转速、膨胀阀开度、风机转速等。输出的预测值为系统的因变参数，主要包括系统各类温度、压力等热力参数。利用健康系统采集的运行数据训练基准模型，实现健康系统的拟合。故障特征提取时将故障数据集的外界参数输入基准模型后得出对应的健康系统热力参数

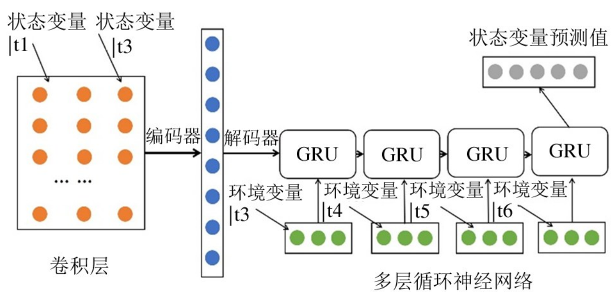

图 2　深度基准模型结构

值，然后与故障数据集实际热力参数值做差即可得到故障系统变化规律。该模型对制冷空调系统拟合效果良好，具体精度分析见文献[8]，可以很好地助力故障特征提取。

1.3　故障偏离特性表征方法

利用基准模型可以得到热力参数实际偏离量，但不同热力参数的量纲不同，难以直观地对不同热力参数偏离程度进行比较。例如对于冷凝温度而言，常态值在 50 ~ 70 ℃，偏离 0.5 ℃并不算大，而对于冷凝器进出风的温差而言，常态值只有 2 ~ 4 ℃，0.5 ℃的偏离已经有较大差异。对于只有 1 MPa 左右的排气压力而言，0.5 MPa 的差异更是明显。本节提出一种偏离数值的去量纲方法，首先计算基准模型在健康数据集上的残差均值和标准差，得到基准模型的归纳偏置和离散程度；然后对故障数据集上的残差按式(1)去量纲，得到故障状态下热力参数偏离量相对于标准差的倍率。

$$r' = (r/\mu)/\sigma \qquad (1)$$

式中，r' 是去量纲后的故障热力参数偏离倍率，r 是故障热力参数偏离量，μ 是健康数据集上残差均值，σ 是健康数据集上残差的标准差。去量纲后的偏离数据对故障特性的表征更加清晰，利用该数据训练诊断模型可以有效提升诊断精度。

2　数据集与平台

本文利用 ASHRAE RP-1043(American Society of Heating, Refrigerating and Air-Conditioning Engineers)公开数据集进行实验分析[20]。该数据集是美国供暖、制冷与空调工程师学会于 1999 年启动的项目，通过对一台 90 冷吨的离心式冷水机组进行故障模拟获取动态运行数据，每种故障包含 4 种不同严重程度，是制冷空调故障诊断领域最常用的数据集。

本文从数据集中选择 6 种常见故障进行分析，包括冷凝器结垢、冷却水流量减少、冷冻水流量减少、含非凝性气体、制冷剂泄漏和制冷剂过充。这 6 种故障属于典型故障，发生频率高、对系统影响大，对其进行故障特征提取研究具有重要意义[20]。

本文数据驱动算法运行平台为 DELL T440 服

务器,GPU 为 GeForce RTX 2080Ti,CPU 为 Intel Xeon Silver 4214,内存为 128 GB,操作系统是 64 位 Windows 10。算法开发环境为 Pycharm,使用 Python 和 Tensorflow 实现。

3　实验分析

本节利用第 1 节所提方法对 ASHRAE RP-1043 数据集的故障特征进行提取。通过数据驱动模型预测故障偏离特性,利用热力学机理分析对其进行修正,可得到更加普适、准确的结论。本节首先对基准模型的精度进行实验验证;然后针对水冷式制冷空调系统的 8 个常见热力参数进行偏离规律分析,分别是蒸发器出水温度(TEO)、冷凝器出水温度(TCO)、蒸发温度(TRE)、冷凝温度(TRC)、吸气温度(T _ suc)、吸气过热度(Tsh _ suc)、排气温度(TR _ dis)和排气过热度(Tsh _ dis)。

3.1　基准模型精度分析

故障偏离特征的提取依赖基准模型精度,因此有必要在数据集上对基准模型进行精度分析。基准模型拟合健康系统的特性,因此使用健康数据训练。12 000 组样本作为训练数据,3000 组不参与训练的样本作为测试数据。使用 Adam 优化器和 MSE 损失函数,训练 100 轮后,测试数据集上的损失值为 0.005。

在 3000 组健康测试数据上验证模型误差,得到特征的误差绝对均值见表 1。这里的误差均值指的是全体样本上预测值和真实值的平均偏离量。如 TEO 的误差均值为 0.1,代表基准模型对该参数预测的平均误差为 0.1 ℃,可见预测精度已非常高,远超物理模型的预测精度,可较好地实现偏离特征提取。

表 1　基准模型的预测误差绝对均值

参数	TEO	TCO	TRE	TRC	T _ suc	Tsh _ suc	T _ dis	Tsh _ dis
误差均值	0.1	0.19	0.15	0.31	0.17	0.20	0.31	0.38

3.2　冷凝器结垢故障特征提取

冷凝器结垢是指水冷式换热器表面沉积水垢,水垢的热阻远大于换热管,使得冷凝器的换热效率下降。冷凝换热效率降低直接导致冷凝器内气态制冷剂体积更多,从而排气压力升高、冷凝温度升高。当膨胀阀开口不变时,阀前压力升高会导致阀后压力升高,蒸发温度也会升高,但阀后压力升高的幅度不会太大。当冷凝器整体换热量下降后,在冷却水流量不变的条件下,理论上会导致冷凝器出水温度降低。为保持热平衡,蒸发器的换热量也会下降,导致冷却水出口温度升高。由于排气压力升高导致压缩机做功增加、产热增加,会使压缩机排气温度升高。而排气过热度是升高还是降低,取决于是排气温度提升大还是冷凝温度提升大。

上述分析得到了系统热力参数的定性偏离规律,进一步通过数据驱动方法对动态运行数据的偏离特征进行提取,结果见图 3。其中,图 3(a)是 8 个参数的平均真实偏离值,图 3(b)是通过去量纲化后的偏离倍率。从图中信息可以对机理分析的结论进

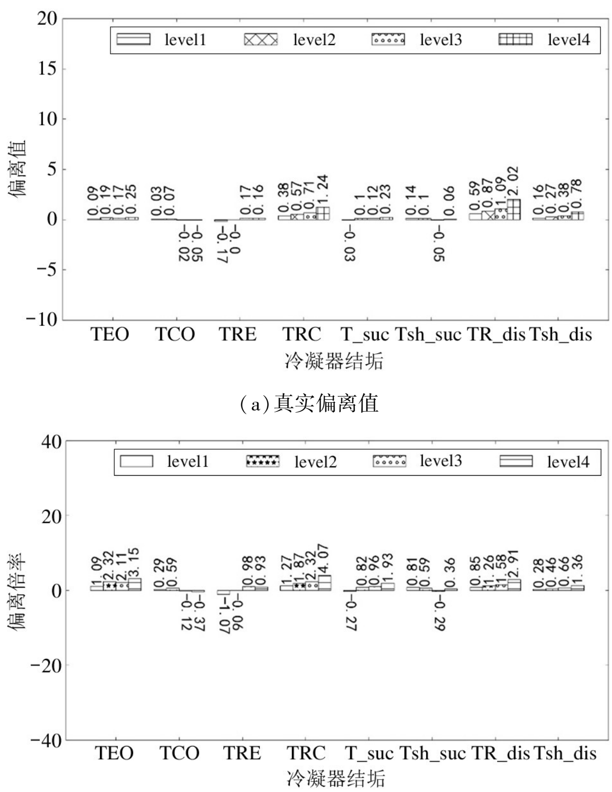

(a)真实偏离值

(b)偏离倍率值

图 3　冷凝器结垢故障偏离特征图

一步验证并完善。如图可知,冷凝器结垢故障的各个参数偏离程度都不大,说明该故障的系统表征不明显。其中变化最大的是冷凝温度和排气温度。这2个参数的偏离程度均随着故障严重程度的增加而增加,在故障最严重时,冷凝温度平均升高约1 ℃,排气温度平均升高约2 ℃。蒸发温度变化不明显,在故障程度较严重时呈现轻微升高,而故障程度较轻时反而有些降低,结合理论分析可知,这种轻微降低的原因来自数据驱动模型误差。冷却水出水温度整体呈现下降趋势,冷冻水出水温度呈现升高趋势,但幅度均较小。吸气温度呈现轻微上升趋势,但吸气过热度变化不明显。

综上,冷凝器结垢故障的系统表征不明显,变化最大的是冷凝温度升高、排气温度升高、冷冻水出水温度升高,升高幅度与故障严重程度正相关,约为1~2 ℃之间,可以作为故障诊断的敏感参数。

3.3 冷却水流量减少故障特征提取

水冷式制冷机组利用循环水对换热器进行换热,其中,用于冷凝器换热的水循环称为冷却水循环。当冷却水流量减少后,冷凝器换热量减少,从而冷凝器内气态制冷剂含量增加、排气压力增加,致冷凝温度升高。经过膨胀阀节流后,吸气压力少量升高,蒸发温度少量提升。由于冷却水流量不足,相同质量的冷却水需要换更多的热量,使得冷却水出口温度升高。而在热平衡的条件下,蒸发器换热量与冷凝器换热量同时减少,使得冷冻水出水温度升高。压缩机吸气温度与该故障相关性不强,由于蒸发温度升高,导致吸气过热度降低。冷凝器换热量减少导致系统内热量堆积,压缩机排气温度升高,排气过热度的趋势取决于冷凝温度和排气温度的升高幅度。

利用数据驱动方法得到图4的偏离特征,进一步对机理分析结论进行完善。由机理分析可知,冷冻水出口温度、冷却水出口温度、蒸发温度、冷凝温度及排气温度都会升高,数据驱动结果则可以直观地看出其升高幅度。冷却水出口温度和冷凝温度的升高幅度最明显,可达2 ℃左右,但结合参数自身量纲,冷却水出口温度的偏离程度更明显,显著高于常规工况。而冷冻水出口温度升高其实并不明显,很难以此作为依据判定该故障。排气温度的值随故障严重程度增加而升高,但故障轻微时没有明显变化,应考虑系统自身冗余因素。蒸发温度提升也不明显,其主要变换依旧取决于膨胀阀开度。最后,由于冷凝温度和排气温度的升高量基本相似,所以排气过热度无明显变化。

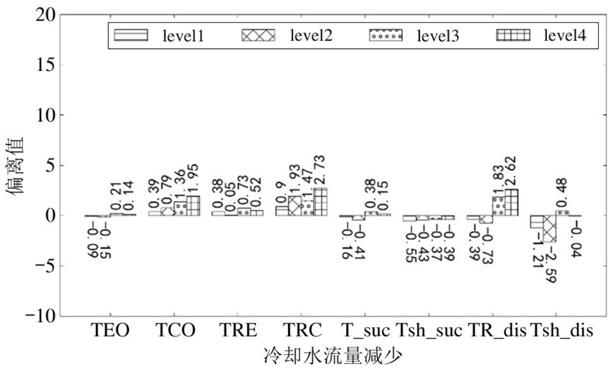

(a)真实偏离值

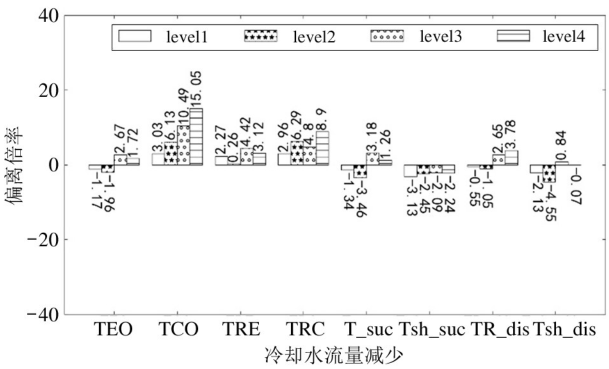

(b)偏离倍率值

图4 冷却水流量减少故障偏离特征图

综上,冷却水流量减少存在2个显著变化,即冷却水出口温度和冷凝温度,其升高量可达2 ℃,可作为该故障的敏感参数。而随着故障程度加深,排气温度也会升高超过2 ℃,蒸发温度升高不足1 ℃。

3.4 冷冻水流量减少故障特征提取

冷冻水用于蒸发器换热,其流量减少会导致蒸发器内冷量无法彻底换出,直接降低系统制冷量。由于冷冻水流量不足,单位质量的冷冻水需要换更多的热,导致冷冻水出口温度明显降低。由于蒸发器换热量不足,导致吸气温度降低,同时吸气过热度降低,当冷冻水严重不足时甚至导致蒸发器无法彻底蒸发,无吸气过热度。由于低压端温度降低,导致

吸气压力降低,蒸发温度降低。

利用数据驱动进一步得到如图 5 所示的偏离特征。可以看出,冷冻水出口温度、蒸发温度、吸气温度和吸气过热度的偏离程度最为明显,其中冷冻水出口温度和吸气温度的降低量可达 2 ℃,相比于该参数自身波动标准差可下降 20 倍以上,见图 5(b)。因此,这 4 个参数可以作为该故障的敏感参数,其表征程度显著。从图中可以进一步看出,冷却水出口温度和冷凝温度也有少量升高,但相较于前面 4 个参数幅度小很多。

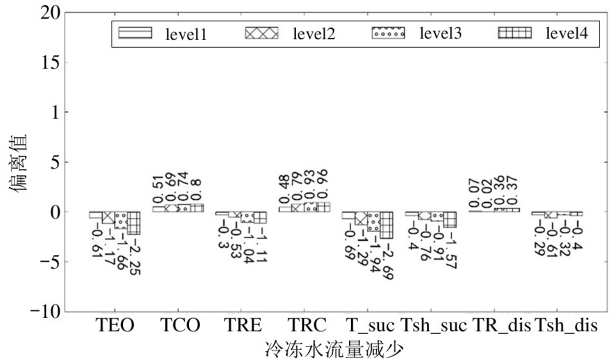

(a)真实偏离值

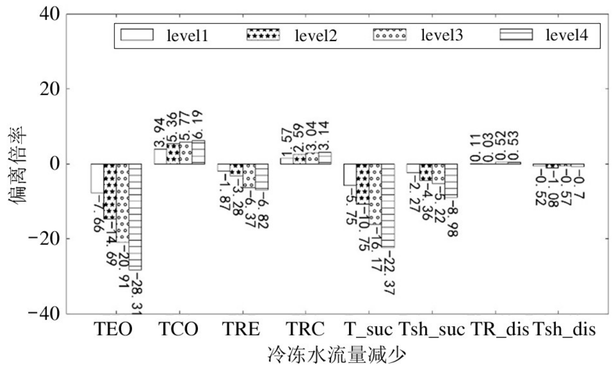

(b)偏离倍率值

图 5　冷冻水流量减少故障偏离特征图

综上,冷冻水出口温度、蒸发温度、吸气温度和吸气过热度 4 个参数的显著降低是该故障的特性,降低量在 1 ~2 ℃。而冷却水出口温度和冷凝温度则存在不足 1 ℃的少量升高。

3.5　含非凝性气体故障特征提取

含非凝性气体指的是充注或维护过程中向系统内混入了无法冷凝的气体,如混入空气等。非凝性气体无法满足制冷系统换热需求,但又会占用系统容量,特别是压缩机容量,使得单位有效质量流量降低,显著降低系统效率。由于存在非凝性气体,使得冷凝器内气体含量升高,进而导致排气压力和冷凝温度升高。排气压力升高导致压缩机做功增加,而由于有效质量流量的降低导致换热量减少,热量堆积致排气温度升高。排气过热度的趋势则取决于冷凝温度和排气温度的升高幅度。此外,由于排气压力升高导致吸气压力对应升高,蒸发温度升高。而换热量降低导致冷冻水出口温度升高、冷却水出口温度降低。换热不足也导致吸气温度升高。

进一步通过数据驱动获得如图 6 所示的偏离特征。对比验证发现,冷凝温度、排气温度和排气过热度的升高最明显,最大可达 11 ℃,相比于标准差的偏离倍率可达 20 倍。分析去量纲化后的图 6(b)可知,冷冻水出口温度、冷却水出口温度、吸气温度和吸气过热度的偏离倍率也很大,可达标准差的 5 ~10 倍。吸气过热度和排气过热度均呈现增大趋势,这是定性机理分析无法得出的结论。

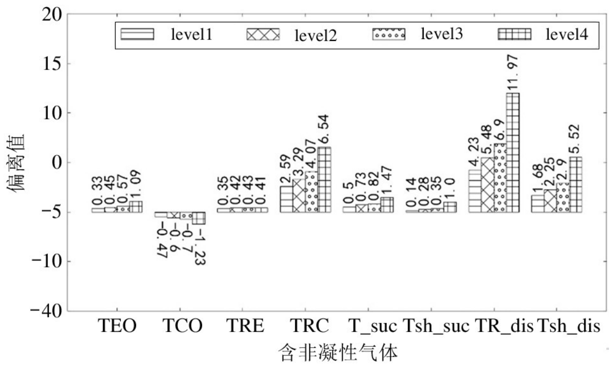

(a)真实偏离值

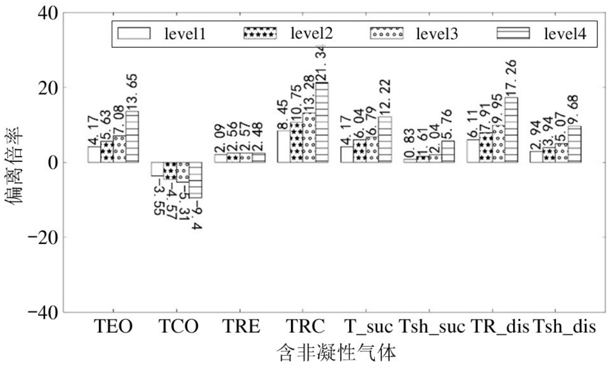

(b)偏离倍率值

图 6　含非凝性气体故障偏离特征图

综上,含非凝性故障的所有分析故障中表征最为明显的一类。冷凝温度、排气温度和排气过热度

3 个参数的变化最为明显,均呈现显著升高,是该故障的敏感参数。此外,冷却水出口温度降低,冷冻水出口温度、吸气温度和吸气过热度升高,也是该故障的明显标志。

3.6 制冷剂充注故障特征提取

制冷剂充注故障指系统的充注量不在合适范围内,通常包括制冷剂泄漏和制冷剂过充。无论制冷剂的充注量是过多还是过少均会导致系统效率下降。当制冷剂泄漏时,由于制冷剂的质量流量减少,会导致冷凝器内气体减少,排气压力和冷凝温度都会降低。更低的排气压力导致压缩机做功减少,产热减少。而另一方面,制冷剂流量减少导致冷凝器换热冗余,使系统含热更少。两方面同时作用下导致排气温度降低,而排气过热度则需要冷凝温度和排气温度共同决定。而制冷剂过充故障的表征与制冷剂泄漏完全相反,原理也是完全相反。

利用数据驱动对 2 种故障数据进行偏离特征提取,结果如图 7 和图 8 所示。可以看出,整体上制冷剂泄漏对参数的影响程度没有制冷剂过充大。制冷

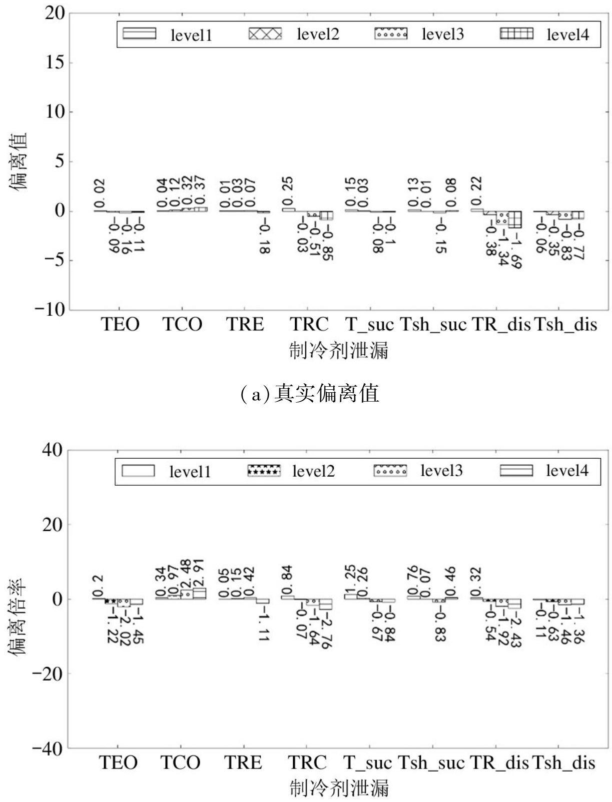

(a)真实偏离值

(b)偏离倍率值

图 7 制冷剂泄漏故障偏离特征图

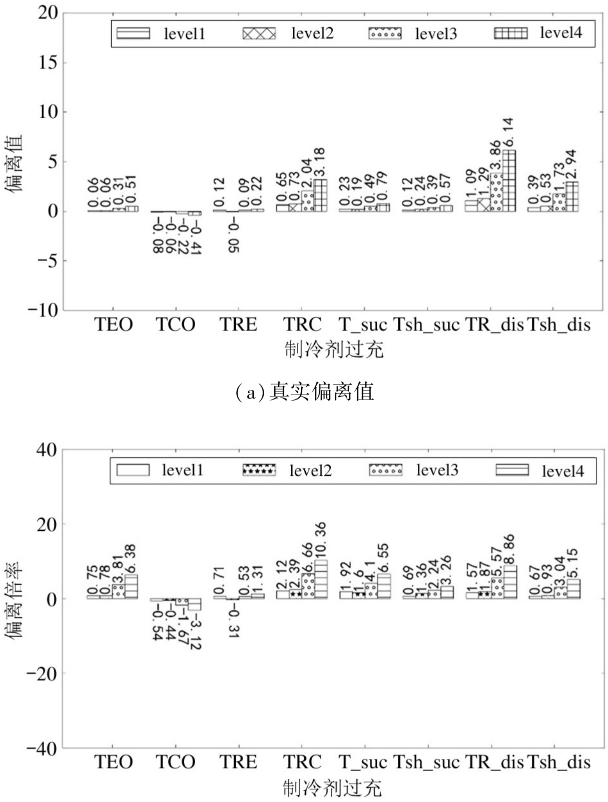

(a)真实偏离值

(b)偏离倍率值

图 8 制冷剂过充故障偏离特征图

剂泄漏时,冷凝温度和排气温度确实会下降,而排气过热度也存在少量下降。另一方面,冷冻水出口温度少量降低,冷却水出口温度少量升高,这是理论分析不容意得出的。进一步通过图 8 的偏离规律进行验证发现,制冷剂过充会明显导致冷凝温度、排气温度和排气过热度升高,升高幅度在 3 ~ 6 ℃。同样地,冷冻水出口温度和冷却水出口温度与制冷剂泄漏的偏离方向相反,分别呈现升高和降低的趋势。

综上,制冷剂充注故障会明显影响冷凝温度、排气温度和排气过热度,当充注量不足时,这 3 个参数会降低,而充注量过高时这 3 个参数会明显升高。此外,充注量对冷冻水和冷却水出口的温度也会产生少量影响。

3.7 偏离特征矢量构建

经过数据和机理联合分析,探明了 6 类故障的偏离规律,并对其偏离现象产生的机理进行了分析,为故障诊断方法研究提供理论基础。本节通过构建特征参数偏离矢量的方式对故障特征进行表征,结果如表 2 所示。表中以↑和↓表示参数的升高或降

低,箭头的数量表示升高或降低的幅度。以相对于标准差的偏离倍率度量,偏离在 2 倍标准差以内的为↑或↓,2 ~5 倍之间为 2↑或 2↓,5 ~10 倍之间为 3↑或 3↓,10 倍以上为 4↑或 4↓。

从表中可以看出,冷却水流量减少、冷冻水流量减少和含非凝性气体故障的偏离特征最明显,而冷凝器结垢和制冷剂泄漏故障的偏离最轻微。从偏离特征的分布来看,不同故障的偏离规律均不相同,且每种故障都有对应的敏感特征,是故障诊断的基础。通过该表格可以建立故障对应的关键特征而降低其他非关键特征对该故障诊断的影响。

表 2　制冷空调系统故障偏离特征矢量表

	TEO	TCO	TRE	TRC	T _ suc	Tsh _ suc	T _ dis	Tsh _ dis
冷凝器结垢	2↑	—	↑	2↑	↑	—	2↑	↑
冷却水流量减少	↑	4↑	2↑	3↑	↑	2↓	2↑	—
冷冻水流量减少	4↓	3↑	3↓	2↑	4↓	3↓	↑	↓
含非凝性气体	4↑	3↓	2↑	4↑	4↑	3↑	4↑	3↑
制冷剂泄漏	↓	2↑	↓	2↓	↓	↓	2↓	↓
制冷剂过充	3↑	2↓	↑	3↑	3↑	2↑	3↑	2↑

4　结　论

本文针对制冷空调系统动态运行数据故障特征提取困难问题,提出一种基于深度学习的参数偏离特征表征方法,在偏离表征基础上结合热力学机理分析,得出制冷空调系统故障状态的敏感参数及其变化规律。具体结论如下。

(1)相比于纯机理分析,利用深度学习技术从制冷空调系统实际运行数据中提出故障特征信息得到的结果更加准确,而定性的机理分析可以使得数据驱动得到的结论更加可信,是一种更优的热力系统故障特征提取方法。

(2)本文分析的 6 类故障中,每类故障都有其自身的敏感参数集,且不同故障间的敏感参数及其偏离规律互不相同。因此,利用敏感参数及其偏离规律实现故障诊断是可行的。

(3)本文分析的 6 类故障中,冷却水流量减少、冷冻水流量减少、含非凝性气体和制冷剂过充故障的系统偏离程度更加明显,其敏感参数的偏离量可超过 2 ℃,相比于健康数据集残差的标准差,偏离倍率可超过 10 倍。而冷凝器结垢和制冷剂泄漏故障的偏离程度较轻,敏感参数的偏离量约为 1 ℃,偏离倍率小于 5 倍。

(4)制冷空调系统参数偏离程度随故障严重程度增加而增加,但当系统故障程度较轻微时,特征参数可能不存在偏离,这与制冷空调系统设计时存在冗余以及系统自身抗扰性有关。

综上,本文通过数据和机理联合分析方法对制冷空调系统故障特征进行了分析研究,得出 6 类故障的参数偏离规律并构建偏离矢量表,可为相关故障诊断研究提供理论基础。

参考文献

[1] 王鑫. 中国争取 2060 年前实现碳中和[J]. 生态经济, 2020,36(12):9-12.

[2] WEI Y, ZHANG X, SHI Y, et al. A review of data-driven approaches for prediction and classification of building energy consumption[J]. Renewable and Sustainable Energy Reviews, 2018,82:1027-1047.

[3] ZHAO Y, LI T, ZHANG X, et al. Artificial intelligence-based fault detection and diagnosis methods for building energy systems: advantages, challenges and the future [J]. Renewable and Sustainable Energy Reviews, 2019, 109:85-101.

[4] KIM W, KATIPAMULA S. A review of fault detection and diagnostics methods for building systems[J]. Science and Technology for the Built Environment, 2018,24:1-18.

[5] YAN K, CHONG A, MO Y. Generative adversarial network for fault detection diagnosis of chillers[J]. Building and Environment, 2020,172:106698.

[6] SUN Z, JIN H, GU J, et al. Studies on the online intelligent diagnosis method of undercharging sub-health air source heat pump water heater[J]. Applied Thermal Engineering, 2020,169:114957.

[7] ZHAO Y, LI T, FAN C, et al. A proactive fault detection and diagnosis method for variable-air-volume terminals in building air conditioning systems[J]. Energy and Buildings, 2019,183:527-537.

[8] SUN Z, JIN H, GU J, et al. Gradual fault early stage diagnosis for air source heat pump system using deep learning techniques[J]. International Journal of Refrigeration, 2019,107:63-72.

[9] FAN Y, CUI X, HAN H, et al. Chiller fault diagnosis with field sensors using the technology of imbalanced data [J]. Applied Thermal Engineering, 2019,159:113933.

[10] GUO Y, TAN Z, CHEN H, et al. Deep learning-based fault diagnosis of variable refrigerant flow air-conditioning system for building energy saving[J]. Applied Energy, 2018,225:732-745.

[11] 杜其通, 刘朝雨, 闵剑, 等. 基于人工神经网络的动力学参数辨识法[J]. 高技术通讯, 2020,30(5):495-500.

[12] 付秀丽, 黎玲萍, 毛克彪, 等. 基于卷积神经网络模型的遥感图像分类[J]. 高技术通讯, 2017,27(3):203-212.

[13] LI Z, SHI S, CHEN H, et al. Machine learning based diagnosis strategy for refrigerant charge amount malfunction of variable refrigerant flow system[J]. International Journal of Refrigeration, 2020,110:95-105.

[14] 任能. 制冷系统故障检测、诊断及预测研究[D]. 上海:上海交通大学, 2008.

[15] 王占伟. 冷水机组故障检测与诊断方法研究[D]. 西安:西安建筑科技大学, 2017.

[16] 张善兴. 变频空调系统热力故障的实验研究[D]. 上海:上海交通大学, 2018.

[17] GUO Y, WANG J, CHEN H, et al. An expert rule-based fault diagnosis strategy for variable refrigerant flow air conditioning systems[J]. Applied Thermal Engineering, 2019,149:1223-1235.

[18] 杜宇婷, 金华强, 顾江萍, 等. 小型全封闭压缩机典型故障壳体振动特性实验研究[J]. 高技术通讯, 2019,29(12):1255-1268.

[19] 张钹, 朱军, 苏航. 迈向第三代人工智能[J]. 中国科学:信息科学, 2020,50(9):1281-1302.

[20] COMSTOCK M, BRAUN J. Development of analysis tools for the evaluation of fault detection and diagnostics in chillers. ASHRAE research project RP-1043[R]. Atlanta: American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc., 1999:99-20.

Data-driven and physical-driven combined fault feature extraction method for refrigeration and air-conditioning systems

SUN Zhe*, JIN Huaqiang***, LI Kang*, GU Jiangping***, HUANG Yuejin*, SHEN Xi* **

(* College of Mechanical Engineering, Zhejiang University of Technology, Hangzhou 310014)

(** School of Engineering, Zhejiang Agriculture and Forestry University, Hangzhou 311300)

(*** College of Education, Zhejiang University of Technology, Hangzhou 310014)

Abstract

The extraction of fault features from refrigeration and air-conditioning systems forms the foundation of fault diagnosis. Most of the existing research uses end-to-end model to achieve autonomous feature extraction. However, the resultant features lack physical analysis and thus, their reliability cannot be guaranteed. Research on interpretable feature extraction for refrigeration and air-conditioning systems is of great significance to achieve reliable fault diagnosis. A combined data-driven and physical-driven method for fault feature extraction is proposed. Focusing on the complex of dynamic operating data, a refrigeration system benchmark model and a deviation characterization strategy are proposed to achieve accurate extraction of fault deviation, and theoretical explanations are combined with thermodynamic mechanism analysis. Finally, the ASHRAE RP-1043 dataset is used for verification, and 6 types of typical fault features are obtained and the deviation feature vector table is constructed to provide a theoretical basis for fault diagnosis.

Key words: data-driven and physical-driven combined method, fault feature extraction, refrigeration and air-conditioning system, deep learning