

文章编号:0253-4339(2026)05-0023-09
doi: 10.12465/issn.0253-4339.20250614001

域对抗迁移学习驱动的地铁列车空调多故障 自适应诊断方法

张同乐¹ 杨 闯² 陈焕新² 张 雪²

(1 华中科技大学中欧清洁与可再生能源学院 武汉 430074; 2 华中科技大学能源与动力工程学院 武汉 430074)

摘 要 地铁空调系统的高效故障诊断对降低能耗和保障乘客舒适度至关重要。本文针对地铁空调运行中特征分布差异大、故障复杂的问题,提出一种基于域对抗神经网络(DANN)的无监督迁移学习故障诊断方法。在多功能综合试验车中采集了冷凝器结垢、通风系统结垢和制冷剂泄漏 3 种单故障及 3 种单故障组合的并发故障数据,在不同工况和压缩机频率下进行迁移学习验证,单故障诊断准确率达 97.30%~98.90%,并发故障诊断准确率为 77.80%~86.70%。使用 UMAP 非线性降维法与 SHAP 模型可解释性工具研究了并发故障诊断精度低于单故障诊断精度的深层原理。将 DANN 与其他 2 种迁移学习模型对比,波动幅度显著小于对比模型。在特征分布差异较大的迁移学习诊断任务中,诊断准确率波动幅度仅为 1%,在并发故障特征重叠时仍保持较高诊断精度。

关键词 地铁空调;故障诊断;迁移学习;域对抗神经网络

中图分类号: U270.38⁺3; TP183; TP306⁺.3

文献标识码: A

Domain-Adversarial Transfer Learning-Driven Adaptive Diagnosis Method for Multi-Faults in Subway Train Air Conditioning Systems

Zhang Tongle¹ Yang Chuang² Chen Huanxin² Zhang Xue²

(1. China-EU Institute for Clean and Renewable Energy, Huazhong University of Science and Technology, Wuhan 430074, China; 2. School of Energy and Power Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract Efficient fault diagnosis of metro train air-conditioning systems is essential for reducing energy consumption and ensuring passenger comfort. This paper proposes an unsupervised transfer learning method based on a domain-adversarial neural network (DANN) to address the challenges involving diverse feature distributions and complex faults. Data obtained from three single faults (condenser fouling, ventilation fouling, and refrigerant leakage) and their concurrent combinations are collected from a multifunctional test vehicle under various operating conditions and compressor frequencies. The DANN achieved accuracy values ranging from 97.30%~98.90% for single faults and 77.80%~86.70% for concurrent faults. Uniform manifold approximation and projection (UMAP) and SHapley Additive exPlanations (SHAP) analyses revealed the underlying reasons for the less accurate concurrent fault diagnosis. Compared with the two baseline transfer learning models, DANN exhibited markedly smaller performance fluctuations, maintaining high accuracy, even under large feature distribution shifts and overlapping concurrent fault features.

Keywords subway air conditioning; fault diagnosis; transfer learning; domain-adversarial neural network

地铁交通凭借快捷、舒适等优点,在大中型城市已成为主要的公共交通方式^[1]。2023 年,中国内地城市轨道交通总能耗为 249.77 亿 kW·h,其中地铁运营能耗量约占 70%^[2]。对于地铁车厢,空调系统的能耗占比高达 46%^[3],若空调系统发生故障,不仅会产生大量的能量损失,还会导致车厢内环境舒适度下降。为

减少地铁能耗,保证地铁运行稳定性,在空调系统中需要应用及时有效的故障诊断方法。

Han H. 等^[4]将支持向量机(support vector machine, SVM)和多标签技术相结合的故障诊断方法应用于建筑冷水机组,对制冷剂泄漏、冷凝器脏堵、冷凝器水流量减少等多种故障进行诊断。周璇等^[5]提出基于

基金项目:国家自然科学基金(51876070)资助项目。(The project was supported by the National Natural Science Foundation of China (No. 51876070).)

收稿日期:2025-06-14;修回日期:2025-09-04;录用日期:2025-09-12

随机森林的制冷剂充注量故障诊断方法,结合基尼指数的特征筛选方法,使算法诊断准确率较SVM模型提高2.9%。Sun Shaobo等^[6]使用基于独立成分分析和BP神经网络的故障诊断方法,在变制冷剂流量空调系统中实现了更高的故障诊断准确率。刘飞天等^[7]构建了基于卷积神经网络和ResNet的离心式冷水机组故障诊断模型。其中通过残差结构优化,ResNet_21模型整体诊断正确率达99.40%。Yan Ke等^[8]提出集成的Wasserstein生成对抗网络,实现了训练数据不足情况下的空调箱故障检测。Jiang Minhui等^[9]利用具有可解释性的XGBoost-SHAP方法,在地铁列车空调系统故障诊断中,解释了单故障诊断中的特征对故障诊断模型输出的贡献。

地铁列车运行中,空调冷负荷会随客流量的变化而波动,引发压缩机频率动态调整,进而改变制冷剂流量、压力等关键指标的分布模式^[10-11],不同环境下的散热差异会使相同故障呈现不同参数特征^[12],导致不同载客量、运行环境的空调数据在特征分布上差异显著。迁移学习能够实现将一个任务的学习信息应用到不同但相关的新任务中,提升新任务的学习效率与性能^[13]。为适应地铁空调系统的多变运行条件,本研究提出基于无监督迁移学习模型的故障诊断方法,并针对3种常见故障及组合形成的并发故障,验证其在不同工况和压缩机频率下的诊断效果。

1 故障诊断方法

本章将展示基于域对抗迁移学习的故障诊断方法,介绍诊断方法使用的域对抗神经网络(domain-adversarial neural network, DANN)以及展示方法整体的构建思路框架。

1.1 域对抗神经网络

域对抗是指通过减小2个不同任务之间的数据分布差异,从而实现知识迁移的方法^[14-15]。DANN的主要模型结构如图1所示,由特征提取器 $G_f(\cdot; \theta_f)$ 、故障分类器 $G_y(\cdot; \theta_y)$ 和领域鉴别器 $G_d(\cdot; \theta_d)$ 构成。训练时,将源域中带故障标签数据与目标域无标签数据输入特征提取器,经其处理后,源域数据用于训练故障分类器,所有数据结合域标签用于训练领域鉴别器。

其中,第1项为故障分类器损失 L_y 反向传播更新特征提取器中与分类相关的参数,第2项为领域鉴别器损失 L_d ,用于衡量判别数据所属域的误差。训练过程通过最大化特征提取器参数 θ_f 对应的领域鉴别器损失,同时最小化领域鉴别器自身参数 θ_d 对应的鉴别




图1 DANN模型结构

Fig.1 DANN model structure

损失,优化其域判别能力,促使特征提取器学习域不变特征,缩小两域数据分布差异。梯度反转层的作用原理由式(1)、式(2)体现: $R(x)$ 为梯度反转层的函数表达,前向传播时不改变输入 x ,但在反向传播时它会将梯度的方向自动反转,并乘以动态权重系数 $-\lambda$ 。其中, I 为单位矩阵, λ 为与模型迭代次数相关的参数,定义由式(3)表示(m 为模型当前迭代次数与总迭代次数的比值,代表当前模型的训练进度),根据训练进度的变化动态调整二者权重,平衡故障分类损失与域鉴别损失,使模型逐步优化、适配复杂场景。

$$R_{\lambda}(x) = x \quad (1)$$

$$\frac{dR_{\lambda}}{dx} = -\lambda I \quad (2)$$

$$\lambda = \frac{2}{1 + e^{-10m}} - 1 \quad (3)$$

1.2 故障诊断模型构建

本研究构建的故障诊断模型以DANN为核心架构,主要由特征提取器、故障分类器和领域鉴别器组成。3个部分均基于反向传播神经网络(backpropagation neural network, BPNN)构建,每层均设置BatchNorm1d批量标准化函数和RELU(rectified linear unit)激活函数,具体层数和神经元设置如表1所示。

1.3 故障诊断策略

本研究的故障诊断流程如图2所示。通过故障试验采集列车空调系统故障运行状态下的实时数据,对原始数据进行预处理,清除非稳态和异常数

表 1 DANN 故障诊断模型结构设置
Tab.1 Settings of DANN fault diagnosis model

层数	特征提取器	故障分类器	领域鉴别器
1	256	256	256
2	256	256	256
3	256	256	256

据、筛选故障数据特征以降低输入数据维度,在保障

故障诊断模型准确率的同时减少运算耗时。将处理后的数据按不同工况和压缩机频率划分,并将源域中的有标签数据以及目标域中的无标签数据划入训练集,在训练过程中多次优化和迭代。模型训练完毕后,使用有标签的目标域数据作为测试集,利用训练后的故障诊断模型对测试集中的故障数据进行诊断分析,并根据每次诊断结果改变模型参数优化诊断精度。




图 2 基于 DANN 模型的故障诊断方法

Fig.2 Fault diagnosis method based on DANN model

2 数据采集及预处理

为模拟地铁列车空调机组的实际运行情况,本研究使用多功能综合试验车进行数据测试。

2.1 试验系统

本研究采用的空调系统为地铁列车中常见的顶置式空调机组,每台机组有 2 个独立的制冷循环,空调系统结构如图 3 所示。温度和压力传感器部署在管道上的不同位置,测量范围和精度如表 2 所示,其中一些参数测量点在图 3 中用×标记。

2.2 数据采集与预处理

本研究对 3 种单故障和 3 种并发故障进行了模

表 2 系统传感器参数

Tab.2 System sensor parameters

传感器类型	测量范围	测量精度
主要温度传感器	-40~150 ℃	±0.3 ℃
辅助温度传感器	-40~200 ℃	±0.3 ℃
湿度传感器	0%~90%RH; 90%~100%RH	±2%; ±3%
主要差压传感器	0~1 000 Pa	±0.25FS%
辅助差压传感器	0~50 Pa	±0.25FS%

拟测试,分别为冷凝器结垢(F1)、通风系统结垢(F2)和制冷剂泄漏(F3)。F1 的模拟试验通过在冷凝器过滤器进风侧覆盖不同层数无纺布滤棉模拟结垢,先使冷凝风机以最大功率运行,持续增加滤棉层数直至进风侧风速接近 0,此时滤棉层数对应 100% 结垢程度;后续分别使用该最大层数的 20%、30%、40%、60% 覆盖过滤器,模拟不同结垢等级。F2 的模拟试验以新风过滤器为操作对象,试验操作与 F1 类似,先使车厢送风风机以最大功率运行,覆盖无纺布滤棉至送风侧风速接近 0,确定 100% 结垢对应的滤棉层数;再分别用该层数的 20%、30%、40%、60% 覆盖过滤器模拟不同结垢等级。F3 的模拟试验以额定制冷剂充注量为基准,通过释放制冷剂分别将充注量减少 10%、20%、30%、40%,模拟不同泄漏程度。故障模拟试验在不同工况和频率下采集数据,每 3 s 1 条,每组工况运行 30 min。3 种并发故障分别由上述 3 种单故障中的任意 2 种同时在空调机组中共同作用产生,分别记为 F1+2、F2+3 和 F1+3。并发故障数据中单故障的等级只包含 20% 和 40% 这 4 种类别的排列组合。

为确保测试结果贴近实际,在进行工况设计时,本研究以地铁车厢空调系统实车运行工况数据的分析结果为参考,遵循较大程度覆盖实际情况的原则




图 3 地铁列车空调系统结构

Fig.3 Subway train air conditioning system structure

设计试验工况,模拟实际机组常见运行环境,具体试验工况如表 3 所示。

表 3 试验工况

Tab.3 Experimental operating conditions

序号	室外温度/℃	回风温度/℃	平均回风湿度/%
工况 1	33	25	70
工况 2	33	28	70
工况 3	35	25	70
工况 4	35	28	70

由于在试验过程中,焓差实验室内的空调机组压缩机为定频压缩机,与实际地铁列车空调机组压缩机为变频压缩机的情况不符,为更好地模拟实际压缩机工作状态,对压缩机进行手动调频改变试验条件,试验中压缩机调节频率为 40、50、55、60 Hz。

对上述试验工况及压缩机频率组合进行各类故障试验操作,采集相应的故障试验数据。在数据采集的过程中出现数值偏离正常范围、特征表现与常规模式不符的异常值,本文通过四分位距异常值剔除法,计算数据的第一四分位数(Q_1)、第三四分位数(Q_3)及四分位距($d_q=Q_3-Q_1$),设定 $Q_1-1.5d_q$ 和 $Q_3+1.5d_q$ 为正常数据范围边界,将超出该边界的样本判定为异常值并剔除。最后依据试验工况与压缩机频率,对数据进行分类整理与容量分配,每个试验工况和压缩机频率分配 2 000 条数据。

2.3 数据特征筛选

采集的数据总共包含 46 个参数,若直接将所有

参数都作为特征参数输入模型用于训练,会导致输入的维度过大。这不仅会增大读取的数据量以及计算复杂度,导致训练时间过长,同时也会导致一些对故障诊断意义较小的参数影响训练的效果。因此在训练诊断模型之前,需要采用合适的特征选择方法,对输入模型的特征进行减维,提高训练效率。

本研究采用基于交叉验证的递归特征消除法(recursive feature elimination and cross validation, RFECV)对数据进行特征筛选。以随机森林算法为基础模型,利用随机森林模型的特征重要性指标,通过递归方式对特征进行重要性排序并逐步剔除低重要性特征,得到各特征的排序。然后基于该排序,依次选取从最小特征选择数量到特征总数范围内不同数量的特征子集,针对每个特征子集进行模型训练,并采用交叉验证以准确率为评估指标计算模型得分,选择交叉验证平均分最高的特征子集作为最佳特征组合。

由于单故障与并发故障的数据特征分布不同,需分别使用 RFECV 方法进行特征筛选。由图 4(a)可知,单故障数据的最佳特征数量为 43 个,相较于原本的特征数量所减少的数量较少。由图 4(b)可知,特征数量为 16 时曲线处于拐点,且累计重要性达到 0.77,已经能够较好地体现故障数据的整体特征分布,因此以 16 为最佳特征数。由图 4(c)可知,并发故障的最佳特征数量为 23 个,已经达到较理想的特征降维效果。特征筛选结果按照特征重要性由高到低排列,如表 4 所示。




图 4 单故障与并发故障特征筛选分析

Fig.4 Feature screening and importance analysis for single and concurrent faults

表 4 46 个特征参数

Tab.4 All 46 feature parameters

序号	单故障筛选结果	并发故障筛选结果
1	喷嘴处含湿量 2	蒸发器进风湿球温度 1
2	系统高压 2	蒸发器出风干球温度 1
3	喷嘴处含湿量 1	机外静压 1
4	机外静压 2	喷嘴入口湿球温度 2
5	喷嘴前后差压 2	蒸发器进风干球温度 1
6	机外静压 1	机外静压 2
7	蒸发器出风湿球温度 1	冷凝器出风温度 2
8	喷嘴流速 2	冷凝器进风干球温度 2
9	蒸发器进风干球温度 2	喷嘴入口干球温度 2
10	喷嘴前后差压 1	喷嘴入口干球温度 1
11	去湿量	蒸发器出风湿球温度 1
12	冷凝器出风温度 2	冷凝器进风湿球温度 1
13	制冷能力偏差	冷凝器出风温度 1
14	系统低压 1	环境大气压
15	蒸发器出风干球温度 1	喷嘴入口湿球温度 1
16	能效比	蒸发器出风干球温度 2
17		喷嘴前后差压 1
18		蒸发器出风湿球温度 2
19		喷嘴前后差压 2
20		蒸发器进风湿球温度 2
21		蒸发器进风干球温度 2
22		冷凝器进风干球温度 1
23		冷凝器进风湿球温度 2

3 故障诊断方法效果验证

本节对不同工况和压缩机频率之间单种故障和并发故障下,所建立模型的迁移学习故障诊断效果

进行了验证。

3.1 单故障诊断

为验证模型在压缩机频率差异场景下的诊断性能,首先利用故障诊断模型开展单故障数据测试。选取系统在 40 Hz 下的运行数据作为源域,分别向 50、55、60 Hz 下的数据作为目标域进行跨域迁移测试,对应记为 f40-50、f40-55、f40-60,构建了 3 组频率迁移诊断任务。将数据的真实标签和模型的预测标签进行对比,计算出模型的准确率,并绘制诊断结果对应的不同故障类型混淆矩阵,如图 5 所示。

在不同压缩机频率间的 3 组测试下,模型准确率分别为 98.90%、98.20% 和 97.30%,总体预测精度保持在较高水平。从混淆矩阵可知,模型在 f40-50 中的预测精度较 f40-55 和 f40-60 更高,且迁移训练的压缩机频率之间差距越大,预测精度越低,契合“频率差距越大,预测精度越低”的客观规律。同时,相较于 f40-50, f40-60 准确率仅下降 3.4%,且混淆矩阵中多数类别仍保持低误判率,验证模型在大跨度频率迁移中具备高稳定性。

同样对于单故障数据,在表 3 所示的 4 种不同工况中,以工况 1 下系统的运行数据作为源域,分别以工况 2、工况 3 和工况 4 下的数据作为目标域进行 3 组故障诊断测试,对应记为 c1-2、c1-3 和 c1-4。测试结果显示对应的预测准确率分别为 95.00%、97.55% 和 96.95%。在不同工况中模型也能对故障进行精确诊断,但较多的误诊结果也反映出模型在处理不同工况下故障诊断时存在一定的波动,体现出工况综合参数变化对诊断结果的影响。

3.2 并发故障诊断

本研究对在同样频率和工况试验中采集的并发




图 5 单故障诊断精度混淆矩阵热力图

Fig.5 Confusion matrix heatmaps for single fault diagnosis accuracy

故障数据进行了诊断,如图 6 所示。针对不同压缩机频率的 3 组并发故障诊断任务,测试结果的准确率依次为 83.80%、82.90% 和 81.75%。可以看出,随着压

缩机频率差距增大,准确率逐步降低,这与单故障诊断中频率差距的影响规律一致,说明频率不同引发的特征分布差异,同样会给并发故障诊断模型带来挑战。




图 6 并发故障诊断精度混淆矩阵热力图

Fig.6 Confusion matrix heatmaps for concurrent fault diagnosis accuracy

在不同工况的并发故障诊断任务中,测试的预测准确率分别为 86.70%、77.80% 和 84.25%。虽然

在并发故障诊断中,预测准确率也同样相对于单故障诊断有所降低,在不同工况的诊断任务中的变化

趋势与单故障任务中有较大差异,体现了并发故障因不同类别故障影响效果交叠给故障数据特征分布带来的复杂变化。

3.3 并发故障诊断精度下降原因探究

根据前文单故障和并发故障的诊断结果对比可知,并发故障的诊断效果显著差于单故障的诊断效果。对于该现象,本文通过非线性降维法 UMAP (uniform manifold approximation and projection),在保留数据原本的整体分布和局部关联的同时,将高维的故障特征数据转化为二维图像形式^[16],并使用 SHAP (SHapley Additive exPlanations) 可解释性工具计算特征对故障类别诊断结果的贡献度,深入探究诊断效果产生差异的原因。

图 7 所示的 UMAP 特征分布二维可视图中,3 种颜色分别代表 3 个不同类别的故障分布情况。图 7 (a) 所示的单故障特征分布中,不同类别的故障分界线清晰可见,而图 7 (b) 所示的并发故障特征分布中,不同类别的故障的特征分布相互混杂,无法分辨出清晰的分界线。

图 8 所示为使用 SHAP 模型绘制的特征分析蜂群图,可知,单故障场景下,核心特征的 SHAP 值分布集




图 7 UMAP 特征分布二维可视图

Fig.7 2D visualization of UMAP feature distributions

中且规律,如 F1 中“喷嘴流速 2”等特征中的高数值对应正 SHAP 值能够推动故障预测,低数值对应负 SHAP 值,抑制故障预测,最后一列的次要特征的综合影响也较为集中,干扰小。但在并发故障场景中,一方面,SHAP 值分布分散性显著提升,次要特征综合影响的分布更宽泛,多特征耦合干扰加剧。另一方面,特征影响方向变得模糊,同一特征的高低取值不再能稳定对应 SHAP 值的正负,不同取值大小的点同时分布在正负 SHAP 值区间,无法通过特征取值高低清晰判断对故障的推动或抑制作用,使并发故障的特征与故障映射关系更加复杂。




图 8 故障特征分析蜂群图

Fig.8 Swarm plots for fault feature analysis

3.4 多模型对比验证

为体现本研究建立故障诊断模型的优越性,使用同样的源域和目标域数据集在同样是迁移学习模型的对抗判别式域自适应 (adversarial discriminative domain adaptation, ADDA) 和特定域网络 (domain-

specific networks, DSN) 模型,以及 DANN 的结构基础模型 BPNN 上进行了测试。ADDA 模型与 DSN 模型的 3 部分结构设置与表 1 所示的 DANN 结构相同, BPNN 设置与 DANN 的故障分类器相同。

ADDA 作为基于对抗学习的迁移模型,具有和

DANN 类似的对抗机制缩小域差异。但不同于 DANN 让域分类器与标签分类器协同对抗, ADDA 聚焦编码器与判别器对抗, 先训练标签分类器, 再让编码器生成特征欺骗判别器, 使特征更具域通用性。

DSN 与 DANN 不同在于, 它除共享特征提取外, 还设私有特征分支。用共享分支学通用特征, 私有分支抓域特有信息, 再借域判别器优化, 相比 DANN 能更细致区分域共性与个性。

图 9 所示为多模型诊断准确率对比。在单故障迁移诊断场景中, DANN 虽在部分特定测试中的准确率略低于 ADDA 和 DSN, 但整体表现稳定, 曲线波动幅度显著小于对比模型。在 f40~60 单故障迁移任务中, ADDA 和 DSN 的准确率波动区间达 10%~15%, 而 DANN 的波动幅度仅约为 1%。在并发故障诊断中, DANN 的诊断性能显著超越 ADDA 和 DSN, 且准确率曲线波动较小, 最大波动幅度小于 5%。




图 9 多模型诊断准确率对比
Fig.9 Comparison of diagnosis accuracy across multiple models

4 结论

为研究如何在运行环境复杂多变的地铁列车空调系统中进行故障诊断, 本研究建立了一种基于 DANN 的无监督迁移学习故障诊断方法, 在不同频率和工况之间实现了单故障 (不同频率间 97.3%~98.90%, 不同工况间 95.00%~97.55%) 以及并发故障 (不同频率间 81.75%~83.80%, 不同工况间 77.80%~86.70%) 的高准确率故障诊断。并通过 UMAP 非线性降维法与 SHAP 模型可解释性工具分析揭示了并发故障诊断结果较差的原因是并发故障中不同故障类别特征分布的叠加和贡献度的偏移。与 BPNN、ADDA、DSN 模型对比, 在单故障迁移诊断中, DANN 整体表现稳定, 虽部分测试准确率略低于

ADDA 和 DSN, 但始终维持较高水平且波动幅度显著更小, 如 f40~60 任务中 DANN 波动仅约 1%。并发故障场景下, DANN 诊断性能显著超越 ADDA 和 DSN, 凭借对抗训练提取故障本质特征, 能够有效应对特征交互导致的域间分布差异, 在多故障特征重叠时仍保持较高诊断精度。

参考文献

- [1] Fan Xianwang, Zhang Huan, Liu Jiali, et al. Numerical analysis of the subway tunnel thermal environment to predict the train-mounted condenser inlet temperature in the cold climate zone of China [J]. Energy and Buildings, 2024, 324: 114928.
- [2] 中国城市轨道交通协会. 城市轨道交通 2023 年度统计和分析报告 [EB/OL]. (2024-03-29) [2025-06-05]. <https://www.camet.org.cn/xytj/tjxx/14894.shtml>. (China Urban Rail Transit Association. Urban rail transit 2023 annual statistics and analysis report [EB/OL]. (2024-03-29) [2025-06-05]. <https://www.camet.org.cn/xytj/tjxx/14894.shtml>.)
- [3] Guan Bowen, Liu Xiaohua, Zhang Tao, et al. Energy consumption of subway stations in China: data and influencing factors [J]. Sustainable Cities and Society, 2018, 43: 451-461.
- [4] Han H, Gu B, Kang J, et al. Study on a hybrid SVM model for chiller FDD applications [J]. Applied Thermal Engineering, 2011, 31(4): 582-592.
- [5] 周璇, 王晓佩, 梁列全, 等. 基于随机森林算法的制冷剂充注量故障诊断 [J]. 华南理工大学学报 (自然科学版), 2020, 48(2): 16-24. (Zhou Xuan, Wang Xiaopei, Liang Liequan, et al. Random forests algorithm-based fault diagnosis for refrigerant charge [J]. Journal of South China University of Technology (Natural Science Edition), 2020, 48(2): 16-24.)
- [6] Sun Shaobo, Li Guannan, Chen Huanxin, et al. A hybrid ICA-BPNN-based FDD strategy for refrigerant charge faults in variable refrigerant flow system [J]. Applied Thermal Engineering, 2017, 127: 718-728.
- [7] 刘飞天, 韩华, 杨钰婷, 等. 基于 CNN 与 ResNet 的离心式冷水机组故障诊断 [J]. 暖通空调, 2023, 53(9): 50-56. (Liu Feitian, Han Hua, Yang Yuting, et al. Fault diagnosis of centrifugal chillers based on CNN and ResNet [J]. Journal of HV&AC, 2023, 53(9): 50-56.)
- [8] Yan Ke, Chen Xinke, Zhou Xiaokang, et al. Physical model informed fault detection and diagnosis of air handling units based on transformer generative adversarial network [J]. IEEE Transactions on Industrial Informatics, 2023, 19(2): 2192-2199.
- [9] Jiang Minhui, Chen Huanxin, Yang Chuang. A metro train

- air conditioning system fault diagnosis method based on explainable artificial intelligence: considering interpretability and generalization[J]. *International Journal of Refrigeration*, 2025, 174: 47–59.
- [10] Zhou Yuanlong, Bi Haiquan, Wang Honglin, et al. Time-delay characteristics of air-conditioning system for subway trains [J]. *Journal of Building Engineering*, 2021, 40: 102731.
- [11] 吴楠楠, 赵亮, 蒋志鹏, 等. 不同气候区地铁列车空调全年动态负荷特性[J]. *制冷*, 2023, 42(1): 43–48. (Wu Nannan, Zhao Liang, Jiang Zhipeng, et al. Analyze on annual load distribution characteristics of metro vehicles air conditioning in different climatic zones [J]. *Refrigeration*, 2023, 42(1): 43–48.)
- [12] 刘俊媛. 地铁区间隧道传热特性研究[D]. 武汉: 华中科技大学, 2022. (Liu Junyuan. Heat transfer characteristics of subway interval tunnels [D]. Wuhan: Huazhong University of Science and Technology, 2022.)
- [13] Ganin Y, Lempitsky V. Unsupervised domain adaptation by backpropagation[C]//The 32nd International Conference on Machine Learning, 2015: 1180–1189.
- [14] 刘玉琳, 白杨, 崔斌, 等. 面向机器学习的自动化特征工程研究综述[J]. *计算机应用与软件*, 2025, 42(1): 1–10. (Liu Yulin, Bai Yang, Cui Bin, et al. A survey on automated feature engineering for machine learning [J]. *Computer Applications and Software*, 2025, 42(1): 1–10.)
- [15] Ben-David S, Blitzer J, Crammer K, et al. Analysis of representations for domain adaptation [M]//Advances in Neural Information Processing Systems 19. Cambridge, MA, USA: The MIT Press, 2007: 137–144.
- [16] 李昕璐, 欧阳瑞志, 高帝逸, 等. 基于时序UMAP和强化学习优化随机森林的碳价格预测模型[J]. *中国高新技术*, 2025(14): 137–139. (Li Xinlu, Ouyang Ruizhi, Gao Diyi, et al. Carbon price forecasting using temporal UMAP and reinforcement learning-optimized random forest [J]. *China High-Tech*, 2025(14): 137–139.)

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:暖通空调数据挖掘;暖通空调故障诊断;空调系统运行优化。

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: data mining in heating, ventilation and air-conditioning; fault diagnosis of heating, ventilation and air-conditioning; operation optimization of air-conditioning system.

(责任编辑:王亚薇)