

基于多尺度域生成网络的冷水机组故障诊断

高学金^{1,2,3,4} 王璇^{1,2,3,4} 姜渴鑫^{1,2,3,4} 高慧慧^{1,2,3,4*} 齐咏生⁵

1. 北京工业大学信息科学技术学院, 北京, 100124
2. 数字社区教育部工程研究中心, 北京, 100124
3. 城市轨道交通北京实验室, 北京, 100124
4. 计算智能与智能系统北京市重点实验室, 北京, 100124
5. 内蒙古工业大学电力学院, 呼和浩特, 010051

摘要:针对领域泛化方法依赖于多个源域数据进行模型训练,但是冷水机组的多工况运行数据获取困难的问题,提出了一种基于多尺度域生成网络(MSDGN)的冷水机组故障诊断方法。利用多尺度编解码卷积神经网络提取源域数据的多尺度特征,引入可学习权重参数动态调整各尺度特征的重要性以增强扩展域的多样性;利用焦损失加强对语义不一致样本的惩罚力度,提高扩展域的语义一致性。结合反向度量学习策略和域分类器最大化源域与扩展域的分布差异,实现训练数据的多样性;采用域对抗策略提取源域和扩展域的域不变特征,引入三元组损失最小化多域之间的分布差异,实现对未知工况的故障诊断。通过生成扩展域来提高模型在未知工况下的故障诊断性能。利用ASHRAE 1043-RP数据集和某城市地铁数据集对所提方法进行了实验验证。ASHRAE 1043-RP数据集实验结果表明,该方法能够在目标工况不可见的情况下有效识别故障,最高诊断正确率高达98.19%。地铁数据集实验结果表明,该方法在真实场景中有一定的实用性。与现有方法相比,所提方法具有更好的故障诊断效果。

关键词:冷水机组;单域泛化;故障诊断;域对抗;度量学习

中图分类号: TP277

DOI:10.3969/j.issn.1004-132X.2026.03.018

开放科学(资源服务)标识码(OSID):



Fault Diagnosis of Chillers Based on Multi-scale Domain Generative Networks

GAO Xuejin^{1,2,3,4} WANG Xuan^{1,2,3,4} JIANG Kexin^{1,2,3,4} GAO Huihui^{1,2,3,4*} QI Yongsheng⁵

1. School of Information Science and Technology, Beijing University of Technology, Beijing, 100124
2. Engineering Research Center of Digital Community, Ministry of Education, Beijing, 100124
3. Beijing Laboratory for Urban Mass Transit, Beijing, 100124
4. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing, 100124
5. School of Electric Power, Inner Mongolia University of Technology, Hohhot, 010051

Abstract: To address the issues that domain generalization methods relied on data from multiple source domains for model training, while obtaining multi-operating condition data for chiller units was challenging, a fault diagnosis method was proposed for chiller units based on multi-scale domain generative network (MSDGN). First, a multi-scale encoder-decoder convolutional neural network was used to extract multi-scale features from source domain data, and learnable weight parameters were introduced to dynamically adjust the importance of features at each scale to enhance the diversity of the extended domain. Then, focal loss was applied to strengthen the penalty for semantically inconsistent samples, improving the semantic consistency of the extended domain. A combination of reverse metric learning strategies and a domain classifier was used to maximize the distribution difference between sources and extended domains, thereby achieving diversity in the training data. Finally, a domain adversarial strategy was employed to extract domain-invariant features from both the source and extended domains, and a triplet loss was introduced to minimize the distribution difference across multiple domains, enabling fault diagnosis for unknown operating conditions. By generating the extended domain, the model's fault diagnosis performance was improved under unknown conditions. The proposed method was experimentally validated using ASHRAE 1043-RP dataset and a metro dataset from a certain city. The results on ASHRAE 1043-RP dataset demonstrate

收稿日期: 2024-12-14

基金项目: 北京市自然科学基金(4222041, 4252027); 北京市教育委员会科研计划(KM202410005034)

that the proposed method effectively identifies faults even when target operating conditions are unseen, achieving a maximum diagnosis accuracy of 98.19%. Results on the metro dataset indicate that the proposed method exhibits practical applicability in real-world scenarios. Compared with existing methods, the proposed approach achieves superior fault diagnosis performance.

Key words: chiller; single domain generalization; fault diagnosis; domain adversarial; metric learning

0 引言

冷水机组的能耗占建筑总能耗的40%^[1],其故障运行会导致额外15%~30%的能源消耗^[2],造成大量的能源浪费,因此,针对冷水机组进行故障诊断研究具有重要意义。冷水机组故障诊断方法分为三类:基于规则的方法^[3]、基于模型的方法^[4]和基于数据的方法^[5]。基于规则和模型的方法严重依赖于冷水机组故障机理等主观先验知识,难以应对日益复杂的设备需求。

近年来,深度学习(deep learning, DL)以其强大的数据处理和特征提取能力被广泛应用于冷水机组故障诊断领域,有效地提高了诊断性能^[6-7]。深度学习具有较强的自适应学习能力,可以自动地从原始数据中提取特征,从而构建端到端的故障诊断模型。然而,传统的深度学习故障诊断方法需要训练集和测试集满足独立同分布的假设^[8],而实际工程中冷水机组工况变化导致数据分布差异较大,严重降低了DL故障诊断方法的性能。因此,迁移学习为解决不同工况下的跨领域故障诊断任务而被提出。其中,领域自适应(domain adaptation, DA)方法能够利用源域数据和部分目标域数据训练模型,提取域不变特征,实现目标域的故障诊断任务^[9-10]。

尽管DA故障诊断方法一定程度上解决了冷水机组变工况故障诊断问题,但它需要目标域数据参与训练,与实际场景中无法提前获取目标域数据的情况相矛盾,限制了其应用。因此,领域泛化(domain generalization, DG)故障诊断方法被提出^[11],其目标是从多个相关源域中学习域无关分类器,以适应不可见目标域的故障诊断。

DG故障诊断方法分为三类:表征学习^[12]、数据操作^[13]和学习策略^[14]。表征学习为主流方法,包括4种代表性技术:核方法^[15]、对抗性学习^[16]、分布对齐^[17]和解纠缠^[18]。例如,LI等^[19]提出一种对抗性域增强泛化方法,通过对抗训练提高模型泛化能力。ZHOU等^[20]利用Wasserstein距离缩小类内距离,实现分类边界优化。

虽然DG故障诊断方法能够解决不可见目标域的故障诊断任务,但它需要多个源域数据进行训

练。然而,冷水机组的多工况运行数据采集成本高昂,可用数据通常来自单一工况,导致DG方法不再适用。

单域泛化(single domain generalization, SDG)故障诊断方法旨在利用单一源域数据进行模型训练,使其在不可见目标域中仍具备良好的诊断性能。这类方法通过数据增强和分布对齐方法实现对目标域的有效诊断^[21]。然而,现有SDG方法的研究主要集中于提高模型的泛化能力,而对扩展域数据的质量问题关注较少。当扩展域数据与源域数据语义相关性不足或分布过于相似时,可能对模型训练产生负面影响,进而导致模型的泛化能力下降。

针对上述问题,本文提出了一种基于多尺度域生成网络(multi-scale domain generative network, MSDGN)的冷水机组故障诊断方法。

1 基本理论

1.1 单源域领域泛化

在故障诊断领域,DG是指通过训练模型在多个源域数据上学习到普适性的特征和决策规则,即域不变表示,使得模型能够有效地对不可见目标域的故障进行诊断。其中工况称为域,设 $D_s^j = \{ \{ x_i^s, y_i^s \}_{i=1}^{N_s} \}_{j=1}^N$ 为源域, $D_t = \{ x_i^t, y_i^t \}_{i=1}^{N_t}$ 为目标域,其中 $x_i^s, x_i^t \in \mathbf{R}^L$, x_i^s 是源域样本, x_i^t 是目标域样本, L 是样本长度, $y_i^s, y_i^t \in \mathbf{R}^{N_c}$ 分别表示源域和目标域样本的健康状态, N_c 表示健康状态个数, N_s 是 x_i^s 的数量, N_t 是 x_i^t 的数量, N 是源域的数量,目标域 D_t 在模型训练阶段不可见,且由于工况的改变, D_t 的数据分布与 D_s 不同,即 $P_t(x^t) \neq P_s(x^s)$ 。与DG不同的是,SDG的 $N=1$,因此SDG故障诊断旨在从单源域数据中学习具有较强泛化能力的模型,使其能够诊断未知目标域的故障。

图1给出了DG和SDG在故障诊断中的原理图。与DG方法相比,由于训练数据的分布单一性,SDG故障诊断更具挑战性。此外,表1提供了SDG故障诊断与一些其他诊断任务的比较。由此可见,相较于其他诊断任务,本文所讨论的SDG没有表中给出的诸多限制,最适合实际应用。

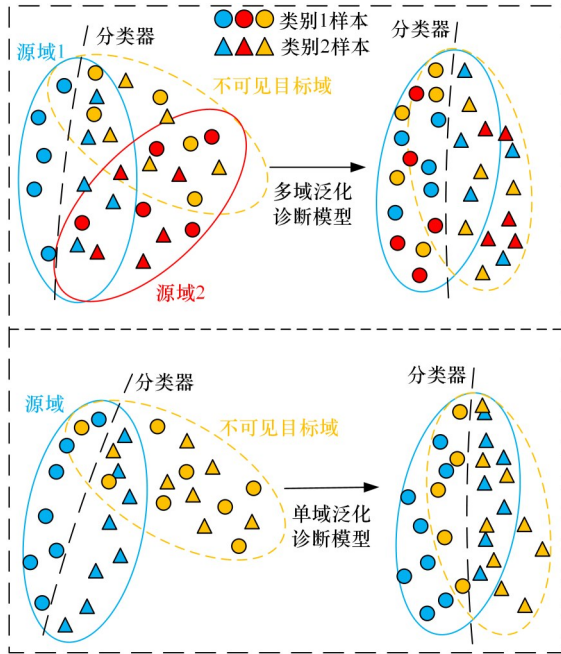


图1 多源域泛化和单源域泛化故障诊断原理图
 Fig.1 Schematic diagram of fault diagnosis principles for multi-source domain generalization and single-source domain generalization

表1 不同诊断任务的比较

Tab.1 Comparison of different diagnostic tasks

诊断任务	源域数量	数据分布	目标域可见
深度学习	1	一致	是
领域自适应	≥ 1	不一致	是
多源域泛化	> 1	不一致	否
单源域泛化	1	不一致	否

1.2 域对抗学习

受生成对抗网络中生成器与判别器对抗训练的启发,域对抗迁移网络(domain-adversarial training of neural networks, DANN)^[22]提出特征提取器与域分类器之间进行对抗训练以提取域不变特征。域分类器用于区分特征来源,而特征提取器则用于提取域无关特征,两者之间利用梯度反转层连接,该层能够在反向传播时反转梯度方向,使得特征提取器和域分类器形成对抗训练。梯度反转层公式如下:

$$R(x) = x$$

$$\frac{dR}{dx} = -I \quad (1)$$

式中: x 为梯度反转层的输入; $R(\cdot)$ 为梯度反转层的伪函数; I 为单位矩阵。

1.3 度量学习

度量学习的核心思想是通过优化某种损失函数以调整特征表示,使得在特征空间中相似的样本更靠近,而不相似的样本则远离。

最大均值差异(maximum mean discrepancy,

MMD)是一种基于核方法的概率分布度量技术,通过计算两个样本在再生核希尔伯特空间中均值的差异来评估其分布之间的差异性。其数学表达式如下:

$$D_{MMD}^2 = \|E_{x \sim P}[k(x, \cdot)] - E_{y \sim Q}[k(y, \cdot)]\|^2 \quad (2)$$

式中: $k(\cdot, \cdot)$ 为核函数; P, Q 表示两个概率分布; $E(\cdot)$ 为期望; x, y 分别为从 P, Q 中采样的样本。

局部最大均值差异(local MMD, LMMD)是MMD的改进形式,它在全局分布差异的基础上进一步引入了样本局部差异的度量,公式如下:

$$D_{LMMD}^2 = \sum_{m=1}^{N_c} \|E_{x \sim P_m}[k(x, \cdot)] - E_{y \sim Q_m}[k(y, \cdot)]\|^2 \quad (3)$$

式中: N_c 为类别数量; P_m, Q_m 分别为源域和目标域中类别 m 的分布。

三元组损失通过在特征空间中拉近锚点和正样本之间的距离来增大锚点和负样本之间的距离,使得相似样本距离更近,公式如下:

$$L_{oss} = \max(0, d(a, p) - d(a, n) + \alpha) \quad (4)$$

式中: a 为锚点样本; p 为正样本; n 为负样本; $d(\cdot)$ 为样本之间的距离函数; α 为边距,控制锚点与负样本之间的最小距离。

2 基于MSDGN的冷水机组故障诊断模型

2.1 MSDGN整体框架

基于MSDGN的冷水机组故障诊断模型整体框架如图2所示。该模型由域生成网络G和任务诊断网络T组成。其中G旨在生成具有与源域数据一致语义且分布不同的扩展域数据。T旨在从源域和扩展域中提取域不变特征,该特征不受域偏移的影响,并包含良好的类信息,适用于目标域的故障诊断。

在数据预处理阶段,将源域样本进行 L_2 归一化处理以消除特征量纲差异带来的影响。之后,将源域样本输入域生成网络G中以合成扩展域。具体而言,样本首先输入多尺度编解码卷积神经网络以生成扩展域。然后利用语义一致性损失与分布差异性损失提高扩展域的质量,使扩展域更加多样化。

获取扩展域数据之后,将源域和扩展域数据输入任务诊断网络T中以提取域不变特征。具体采用对抗学习策略,通过特征提取器 T_e 和域判别器 T_d 之间的对抗训练学习域不变表示。在此基础上,利用三元组损失衡量域不变特征之间的分布差异,增强模型的泛化能力。

本文模型在增强源域数据的基础上进一步提高了扩展域的语义一致性与分布差异性,同时使用域对抗训练和三元组损失提高模型的泛化性

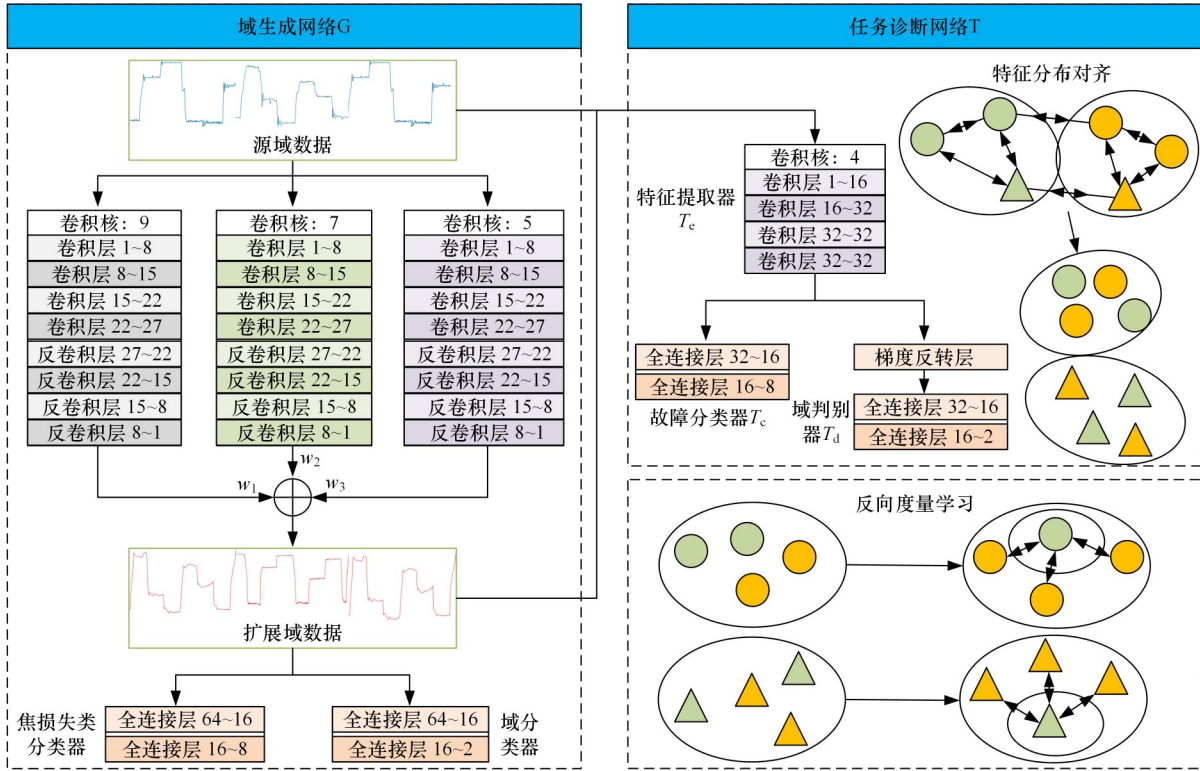


图2 MSDGN整体框架

Fig.2 Overall framework of MSDGN

能,实现目标域的故障诊断任务。

2.2 域生成网络 G

域生成网络 G 通过多尺度特征动态融合、最大化分布差异和语义一致性约束实现高质量扩展域的生成,具体描述如下。

1)多尺度特征动态融合。如图3所示,单源域样本 x_i^s 输入扩展域生成器 G_g 中得到特征组 $f_i^s, i=1, 2, 3$, 其中 U1、U2 和 U3 为卷积核大小不同的编解码卷积神经网络。由于不同尺度的特征对冷水机组数据分布变化的敏感度存在差异,因此引入可学习权重参数动态调整各尺度特征的重要性,具体公式如下:

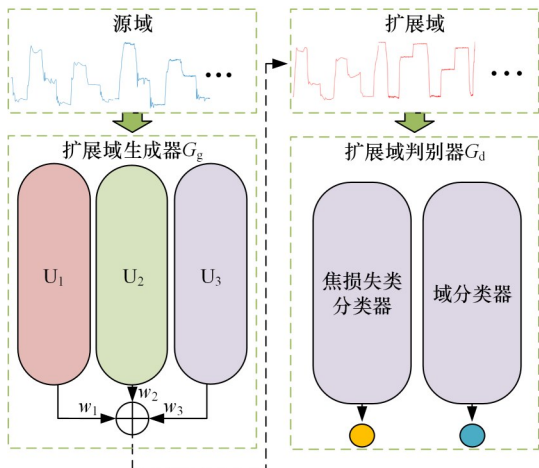


图3 域生成网络结构图

Fig.3 Domain generation network architecture diagram

$$\hat{x}_i = \frac{1}{E} \sum_{i=1}^E w_i f_i^s \quad (5)$$

式中: \hat{x}_i 为扩展域样本; E 为特征组组数; w_i 为可学习权重参数,在反向传播过程中,网络通过梯度下降算法自动优化 w_i 。

2)最大化分布差异。为了优化扩展域的分布差异性,设计了分布差异性损失。具体实现为:利用扩展域判别器 G_d 的域分类器判别源域和扩展域的域信息,同时最大化扩展域生成器 G_g 的 LMMD 来增加两域之间的距离。 G_g 与 G_d 的损失函数表示为

$$L_g = -D_{LMMD}(G_g(x_i^s, y_i^s), D_s) \quad (6)$$

$$L_d = \frac{1}{N_s} \sum_i L_{CE}(G_d(x_i^s), d) + \frac{1}{N_t} \sum_i L_{CE}(G_d(\hat{x}_i), \hat{d}) \quad (7)$$

式中: $L_{CE}(\cdot)$ 为交叉熵损失函数; N_s 为源域样本个数; D_s 为源域; d, \hat{d} 分别为源域和扩展域样本的域标签。

3)语义一致性约束。考虑到扩展域生成器 G_g 在训练过程中可能会生成语义不相关的硬样本,因此有必要设计语义一致性损失加强生成样本的约束,保证生成样本中包含丰富的状态信息,提高生成样本的质量。在此借鉴焦损失^[23]的思想引导 G_g 加大对硬样本的惩罚力度。具体而言,通过在交叉熵损失的基础上引入一个额外的聚焦参数来调整损失函数的权值,从而对难以分类的样本施加更大的惩罚。具体公式如下:

$$L_{focal} = -(1 - \hat{y}_c)^{\gamma} y_c \log(\hat{y}_c) \quad (8)$$

其中： \hat{y}_c 为焦损失类分类器输出的第 c 类故障对应的预测值，反映样本的分类难度； y_c 为样本真实标签对应第 c 类故障的one-hot值； γ 为可调聚焦参数，控制对样本的惩罚程度。通过降低易分类样本的权重以提高难分类样本的权重，提高模型对硬样本的关注度，并在训练过程中逐渐排除硬样本，避免了无效样本的产生，提高了模型的学习能力。

2.3 任务诊断网络T

如图4所示，T采用域对抗训练形成 T_e 和 T_d 之间的对抗，同时加入三元组损失进一步增强域不变表征的学习能力，实现域不变特征的提取。然后利用监督学习进行故障分类，具体描述如下。

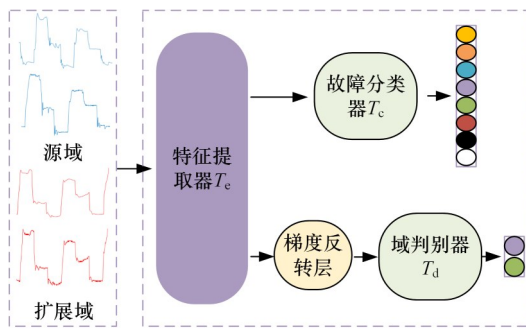


图4 任务诊断网络结构图

Fig.4 Task diagnostic network architecture diagram

1)域对抗训练。将单源域和扩展域样本输入 T_e 中，输出域不变特征，特征分别输入故障分类器 T_c 和梯度反转层。采用三元组损失计算域不变特征之间的距离，具体公式如下：

$$L_e = \frac{1}{N_s} L_{\text{oss}}(T_c(x_i^s), y_i^s) + \frac{1}{N_s} L_{\text{oss}}(T_c(\hat{x}_i), \hat{y}_i) \quad (9)$$

式中： \hat{y}_i 为与源域样本对应的目标域样本的标签。

2)监督学习。 T_c 输出单源域和扩展域样本的预测标签，并计算预测输出与真实标签的交叉熵损失，其中扩展域的生成样本与源域样本一一对应，因此共享标签空间，具体计算公式如下：

$$L_{\text{task}} = \frac{1}{N_s} \sum_i L_{\text{CE}}(T_c(T_e(x_i^s)), y_i^s) + \frac{1}{N_s} \sum_i L_{\text{CE}}(T_c(T_e(\hat{x}_i)), \hat{y}_i) \quad (10)$$

将梯度反转层的输出输入到 T_d 中进行域判别，损失表示为

$$L_{\text{id}} = \frac{1}{N_s} \sum_i L_{\text{CE}}(T_d(T_e(x_i^s)), d) + \frac{1}{N_s} \sum_i L_{\text{CE}}(T_d(T_e(\hat{x}_i)), \hat{d}) \quad (11)$$

2.4 网络优化过程

在MSDGN中，对G和T进行参数优化，采用自适应矩估计方法通过反向传播更新模型参数。首先对G进行优化，包括参数 θ_g 、 θ_d 。训练好

G之后优化T，包括参数 θ_e 、 θ_c 、 θ_{id} 。G的优化目标函数为

$$\min_{\theta_e, \theta_d} L_G = L_{\text{local}} + L_d + L_g \quad (12)$$

T的优化目标函数为

$$\min_{\theta_e, \theta_c, \theta_{\text{id}}} L_T = L_e + L_{\text{task}} + L_{\text{id}} \quad (13)$$

3 实验与分析

为了验证所提方法的有效性，利用美国公开数据集和地铁数据集进行了全面实验验证，并与其他领域泛化方法进行了对比。

3.1 1043-RP数据集实验

本实验数据集来源于美国采暖、制冷和空调工程师协会(ASHRAE)1043-RP项目收集的冷水机组不同健康状态的运行数据^[24]。1043-RP项目针对一台90 t(316 kW)的离心式冷水机组，测试了7种常见的冷水机组故障，包括油过量(EO)、不凝性气体(NC)、制冷剂泄漏(RL)、制冷剂过充(RO)、蒸发器水流量减少(FWE)、冷凝器水流量减少(FWC)和冷凝器结垢(CF)。每种故障按故障程度划分为4个故障等级，4个故障等级以10%的故障程度依次递增，通过改变冷却水温度、冷冻水温度和冷水机组冷负荷3个控制变量，收集了27种不同工况下的冷水机组运行数据。每种工况至少运行30 min后达到稳定状态。每种工况的训练数据集包含4000个样本，测试数据集包含1600个样本。数据集共有8个类别，一个正常类别和7个故障类别。运行数据是关于时间和特征的二维时序数据，特征数为64。传感器采样周期为10 s，被安装在蒸发器、冷凝器、压缩机、节流装置等关键部件处监测机组状态。

本文采用A、B、C 3种不同工况下的稳态数据进行实验，将3个工况分别看成单源域和目标域并组成6种诊断任务，每种诊断任务运行5次取平均值作为最终结果，以避免实验偶然性。

工况A、B、C具体设置如表2所示，表3展示了3个工况组成的6种诊断任务。训练学习率为0.0001，训练轮次为1000。在模型训练期间，测试工况的数据是不可见的。

表2 工况设置

Tab.2 Operating condition settings

工况	1043RP数据集		地铁数据集
	控制变量	数值/°C	日期
A	冷却水温度	40	9月19日
B	冷却水温度	45	9月21日
C	冷却水温度	50	9月22日

表3 诊断任务设置

Tab.3 Diagnostic task settings

诊断任务	源域	目标域
T ₀	A	B
T ₁	A	C
T ₂	B	A
T ₃	B	C
T ₄	C	A
T ₅	C	B

通过与卷积神经网络(CNN)、域对抗迁移网络(DANN)^[22]、对抗性互信息网络(AMINet)^[25]和单域增量生成网络(SDIGN)^[26]方法对比来验证本文方法的有效性。

3.2 1043-RP数据集诊断结果分析

域生成网络G的超参数和任务诊断网络T的超参数设置如图2所示,将训练好的模型与其他方法进行对比,结果如表4所示。由表4可知,所提方法在整体诊断任务上表现优异,与CNN的基本结果相比,其余4种方法提高了对所有任务的平均诊断准确率。具体而言,本文提出的MSDGN在每个任务上都实现了准确率的提高。在某些诊断任务上(如T₀和T₅)优势明显,模型能够很好地泛化到目标域。但在某些任务上(如T₂和T₄)效果有所降低,但依旧取得了最好的诊断正确率,其原因在于不同工况数据作为源域时,生成的扩展域数据质量有所不同,影响了域不变特征的提取效果。从总体上看,本文方法在所有任务上取得了最高

表4 1043-RP数据集不同方法诊断实验结果

Tab.4 Diagnostic experiment results of different methods on 1043-RP dataset %

		CNN	DANN	AMINet	SDIGN	MSDGN
任务	T ₀	82.31	91.81	97.86	83.68	98.19
	T ₁	80.89	85.31	92.32	87.62	93.75
	T ₂	85.25	85.13	82.68	81.12	89.19
	T ₃	86.31	89.31	92.31	85.32	93.25
	T ₄	67.54	80.94	76.62	81.36	88.13
	T ₅	83.69	84.25	85.31	83.04	97.31
均值		80.99	86.12	87.85	83.69	93.30

的均值,说明本文方法鲁棒性最好。

为了直观地解释MSDGN在SDG任务中的影响,图5展示了所有比较方法在诊断任务T₃的最终特征提取器提取的特征分布。相同颜色的散射点代表相同的类别,不同形状的散射点代表不同工况下提取的特征。从图中发现,CNN提取的特征有多个类混合在一起,类间可分性较差;DANN由于仅使用单源域训练,域对齐效果较弱,部分类间可分性表现较差;与DANN相比,AMINet在互信息对抗学习的作用下提高了类间可分性,但部分域对齐效果较差;SDIGN整体类间可分性和类内聚合性有一定提高,但个别类别对齐效果较差。相比之下,本文方法通过增强源域数据增强了类别之间的可分性,同时提高了模型的域不变特征提取能力,在目标域上取得了良好的效果。

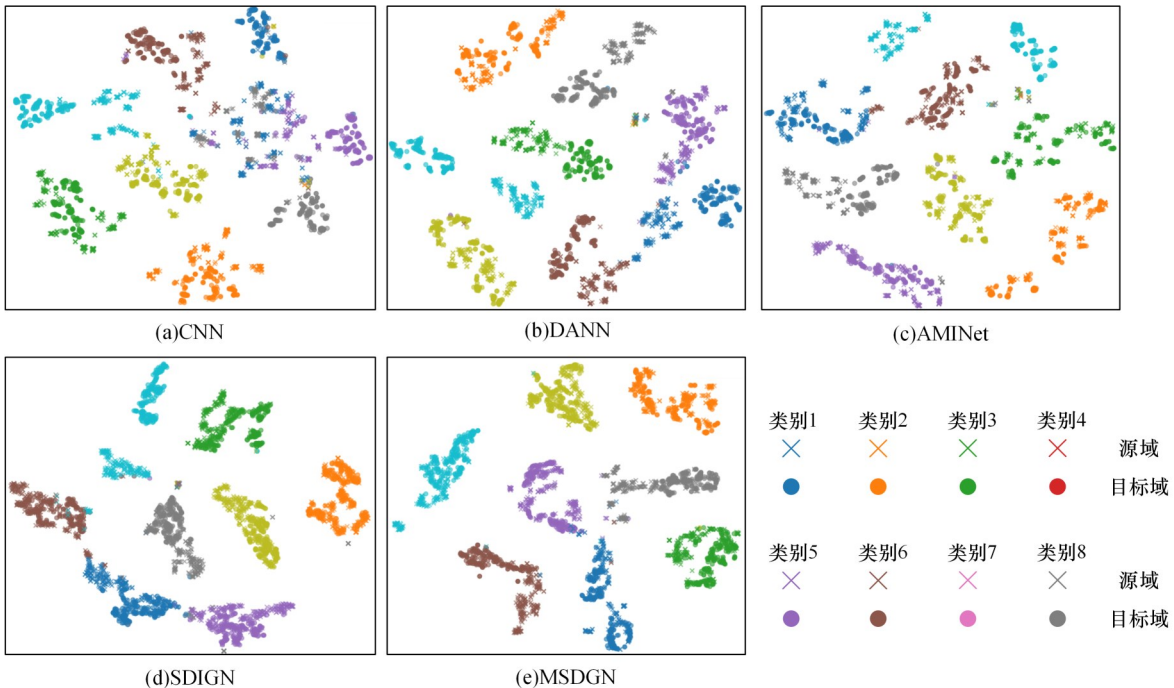


图5 不同方法在T₃任务提取的特征可视化

Fig.5 Feature visualization extracted by different methods on task T₃

为说明所提创新点的有效性,开展了消融实验,实验设置如表5所示,实验结果如图6所示。结果表明,在6个诊断任务中,本文方法相较于消融方法,在 T_0 、 T_2 、 T_3 、 T_4 以及 T_5 任务中均取得了最优诊断效果。而在 T_1 任务中,本文方法的诊断正确率略低于 A_1 方法。这一现象主要是因为焦损失通过降低易分类样本的权重,使模型更加关注难分类样本,从而提高模型对复杂样本的识别能力。然而,当任务中难分类样本较少时,焦损失可能因过度关注难分类样本而影响整体性能,导致精度略有下降。这也解释了源域相同的 T_0 与 T_1 任务中, A_1 方法与本文方法的诊断正确率非常接近的原因。尽管如此,对于冷水机组数据而言,样本分类困难是一种普遍现象,这从本文方法在除 T_1 任务外的其他任务中均取得了最优诊断正确率即可看出。 T_1 任务中 A_1 方法精度略高的现

象仅属于特殊情况,并不影响本文方法在整体任务中的显著优势。因此,所采用的多尺度卷积神经网络、可学习权重参数和焦损失函数能够提高生成样本的多样性和有效性,进而增强模型的泛化能力。具体而言,多尺度编解码卷积神经网络能够提取单源域样本的不同尺度特征,可学习权重参数能够自动根据特征贡献度调整权重大小,焦损失函数能够对低质量样本加大惩罚力度,避免硬样本的生成。因此,本方法能获得较满意的诊断结果。

表5 消融实验设置

Tab.5 Ablation experiment settings

方法	描述
A_0	移除可学习权重参数
A_1	将焦损失函数替换为交叉熵损失函数
A_2	将多尺度卷积层替换为普通卷积层




图6 消融实验结果

Fig.6 Results of ablation experiments

3.3 地铁数据集实验

如图7所示,地铁冷水机组数据来源于北方某城市地铁冷水机组9月日常运行数据,机组包括正常(NO)和压缩机故障(CPF)两种状态。由于外界环境的变化,冷水机组运行工况一直处于微小变化中,因此将一天的数据作为一个工况。采集发生故障的3天运行数据作为3个工况进行实验。运行数据是关于时间和特征的二维时序数据。传感器采样周期为10s,采集蒸发器出口温度和压力、蒸发器进口温度和压力、冷凝器出口温度和压力以及冷凝器进口温度和压力8个特征。现场采集数据后制成表格,根据机组运行状态随机截取正常运行数据和故障运行数据组成实验数据集。然后依据特征对每类数据进行数据预处理,消除不同特征之间的数值范围差异。具体而言,以类为单位将数据沿特征方向进行 L_2

归一化处理,最终得到经过预处理的标准化数据集,将数据集划分为训练数据和测试数据,每种工况的训练集包含1600个样本,测试集包含600个样本。

数据集工况设置如表2所示,诊断任务设置如表3所示。由于数据集的变化,网络的超参数



图7 地铁冷水机组示意图

Fig.7 Schematic diagram of metro chiller system

做出相应调整,域生成网络G和任务诊断网络T的超参数设置如表6、表7所示。表中in表示输入,out表示输出,kernel表示卷积核大小。扩展域生成器使用多尺度编解码卷积神经网络,因此每层写3个卷积核大小代表不同尺度的卷积层。

表6 域生成网络超参数设置

Tab.6 Hyperparameter settings for domain generation network

		参数设置	激活函数
扩展域生成器	卷积层1	in为1,out为8,kernel为1,2,2	ReLU
	卷积层2	in为8,out为15,kernel为1,2,2	ReLU
	卷积层3	in为15,out为22,kernel为1,2,2	ReLU
	卷积层4	in为22,out为27,kernel为1,2,2	ReLU
	反卷积层1	in为27,out为22,kernel为1,2,2	ReLU
	反卷积层2	in为22,out为15,kernel为1,2,2	ReLU
	反卷积层3	in为15,out为8,kernel为1,2,2	ReLU
焦损失类分类器	全连接层1	in为8,out为4	ReLU
	全连接层2	in为4,out为2	Softmax
域分类器	全连接层1	in为8,out为4	ReLU
	全连接层2	in为4,out为2	Softmax

表7 任务诊断网络超参数设置

Tab.7 Hyperparameter settings for task diagnostic network

		参数设置	激活函数
特征提取器	卷积层1	in为1,out为16,kernel为1	ReLU
	卷积层2	in为16,out为16,kernel为2	ReLU
	池化层1	size为2	ReLU
	卷积层3	in为16,out为32,kernel为2	ReLU
	卷积层4	in为32,out为32,kernel为2	ReLU
	池化层2	size为2	ReLU
故障分类器	全连接层1	in为64,out为16	ReLU
	全连接层2	in为16,out为2	Softmax
域判别器	全连接层1	in为64,out为16	ReLU
	全连接层2	in为16,out为2	Softmax

3.4 地铁数据集诊断结果分析

为验证本文方法在真实场景中的诊断效果,利用真实地铁冷水机组运行数据进行实验。表8展示了所有方法在模型训练完成后的诊断结果,可以看出,所提出的方法在真实数据集上仍表现出较好的诊断效果。与对比方法相比,本文方法在所有诊断任务中取得了最高的平均诊断正确率,其中T₁任务的诊断正确率达到了93.56%。但在T₀、T₂以及T₃任务中,本文方法的诊断正确率低于AMINet。这一结果表明,基于互信息最大最小博弈的策略在提取域不变特征方面具有一定优势。然而在实际应用场景中,整体性能的稳定比单一任务的优越性更为重要,这使得模型

在面对任意未知数据时均能保持理想的诊断效果,从而更符合实际工程需求。因此,MSDGN方法具有一定的实用价值。相比于公开数据集1043-RP,地铁数据集由于环境复杂性和数据分布差异性,使得诊断任务更加具有挑战性。从不同任务的诊断正确率看,真实数据集的工况差异性更大,生成的扩展域数据质量存在一定差异,从而导致诊断正确率在任务间存在显著差异。MSDGN在所有任务中的诊断正确率均值达到80.83%,显著高于CNN、DANN、AMINet和SDIGN方法,充分证明了MSDGN在复杂实际场景中的有效性。

表8 地铁数据集不同方法诊断实验结果

Tab.8 Diagnostic experiment results of different methods on metro dataset %

		CNN	DANN	AMINet	SDIGN	MSDGN
任务	T ₀	62.31	82.11	91.83	51.37	87.67
	T ₁	55.33	76.17	83.33	53.88	93.56
	T ₂	62.16	77.16	84.33	68.12	79.19
	T ₃	59.31	66.83	79.83	55.32	68.66
	T ₄	55.12	62.11	65.33	66.36	70.33
	T ₅	58.59	76.83	66.16	77.04	85.54
均值		58.81	73.54	78.46	62.02	80.83

4 结论

本文提出了一种基于多尺度域生成网络(MSDGN)的冷水机组故障诊断方法,用于冷水机组在仅有唯一源域可用来训练模型的前提下实现未知工况的故障诊断。在ASHRAE 1043-RP数据集和地铁数据集上进行了充分的实验,验证了基于MSDGN的故障诊断方法的有效性。根据实验结果得出以下结论:

1)MSDGN有效降低了现有DG方法对多源域数据的依赖性,优于先进的领域泛化方法。通过合成扩展域,外泛化单源域的数据分布,同时考虑扩展域的语义一致性和分布差异,保证生成数据的可靠性和多样性。

2)ASHRAE 1043-RP数据集实验结果表明,MSDGN优于CNN、DANN、AMINet和SDIGN,能够实现不可见工况的诊断任务,最高诊断正确率达到98.19%。地铁数据集实验结果表明,MSDGN具有实际应用价值,在真实复杂环境中能够有效诊断冷水机组故障。

参考文献:

[1] AFSHARI A, FRIEDRICH L. A Proposal to Introduce Tradable Energy Savings Certificates in the Emirate of Abu

- Dhabi[J]. *Renewable and Sustainable Energy Reviews*, 2016, 55: 1342-1351.
- [2] KATIPAMULA S, BRAMBLEY M R. Review Article: Methods for Fault Detection, Diagnostics, and Prognostics for Building Systems—a Review, Part I[J]. *HVAC&R Research*, 2005, 11(1): 3-25.
- [3] 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): 3-21.
- [4] NIU Jide, ZHOU Ruoyu, TIAN Zhe, et al. Energy-saving Potential Analysis for a 24-hour Operating Chiller Plant Using the Model-based Global Optimization Method[J]. *Journal of Building Engineering*, 2023, 69: 106213.
- [5] ZHANG Hanyuan, YANG Wenxin, YI Weilin, et al. Imbalanced Data Based Fault Diagnosis of the Chiller via Integrating a New Resampling Technique with an Improved Ensemble Extreme Learning Machine[J]. *Journal of Building Engineering*, 2023, 70: 106338.
- [6] ZHANG Boyan, WANG Peng, LIU Guangyu, et al. Diagnosis of Single and Multiple-source Faults of Chiller Sensors Using EWEEMD-ICKNN by Time Sequence Denoising and Non-Gaussian Distribution Feature Extraction[J]. *Energy and Buildings*, 2023, 298: 113572.
- [7] 温楷儒, 陈祝云, 黄如意, 等. 基于可解释时空图卷积网络的多传感数据融合诊断方法[J]. *机械工程学报*, 2024, 60(12): 158-167.
- WEN Kairu, CHEN Zhuyun, HUANG Ruyi, et al. Multi-sensor Data Fusion Diagnosis Method Based on Interpretable Spatial-Temporal Graph Convolutional Network[J]. *Journal of Mechanical Engineering*, 2024, 60(12): 158-167.
- [8] SCHÖLKOPF B. *Causality for Machine Learning*[M]// *Probabilistic and Causal Inference*. New York: ACM, 2022: 765-804.
- [9] Van de SAND R, CORASANITI S, REIFF-STEPHAN J. Data-driven Fault Diagnosis for Heterogeneous Chillers Using Domain Adaptation Techniques[J]. *Control Engineering Practice*, 2021, 112: 104815.
- [10] ZHU Xu, CHEN Kang, ANDUV B, et al. Transfer Learning Based Methodology for Migration and Application of Fault Detection and Diagnosis between Building Chillers for Improving Energy Efficiency[J]. *Building and Environment*, 2021, 200: 107957.
- [11] WANG Jindong, LAN Cuiling, LIU Chang, et al. Generalizing to Unseen Domains: a Survey on Domain Generalization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(8): 8052-8072.
- [12] JIN Xin, LAN Cuiling, ZENG Wenjun, et al. Style Normalization and Restitution for Domain Generalization and Adaptation[J]. *IEEE Transactions on Multimedia*, 2021, 24: 3636-3651.
- [13] YUE Xiangyu, ZHANG Yang, ZHAO Sicheng, et al. Domain Randomization and Pyramid Consistency: Simulation-to-Real Generalization without Accessing Target Domain Data[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, 2019: 2100-2110.
- [14] WU Guile, GONG Shaogang. Collaborative Optimization and Aggregation for Decentralized Domain Generalization and Adaptation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2021: 6464-6473.
- [15] BLANCHARD G, DESHMUKH A A, DOGAN U, et al. Domain Generalization by Marginal Transfer Learning[J]. *Journal of Machine Learning Research*, 2021, 22(2): 1-55.
- [16] ZHAO S, GONG M, LIU T, et al. Domain Generalization via Entropy Regularization[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 16096-16107.
- [17] ZHU Ronghang, LI Sheng. Self-supervised Universal Domain Adaptation with Adaptive Memory Separation[C]//2021 IEEE International Conference on Data Mining (ICDM). Auckland, 2021: 1547-1552.
- [18] YU Xi, TSENG H H, YOO S, et al. INSURE: an Information Theory iNspired diSentanglement and pURification model for Domain Generalization[J]. *IEEE Transactions on Image Processing*, 2024, 33: 3508-3519.
- [19] LI Qi, CHEN Liang, KONG Lin, et al. Cross-domain Augmentation Diagnosis: an Adversarial Domain-augmented Generalization Method for Fault Diagnosis under Unseen Working Conditions[J]. *Reliability Engineering & System Safety*, 2023, 234: 109171.
- [20] ZHOU Fan, JIANG Zhuqing, SHUI Changjian, et al. Domain Generalization via Optimal Transport with Metric Similarity Learning[J]. *Neurocomputing*, 2021, 456: 469-480.
- [21] JIANG Kexin, GAO Xuejin, GAO Huihui, et al. VIT-GADG: a Generative Domain-generalized Framework for Chillers Fault Diagnosis under Unseen Working Conditions[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3527413.
- [22] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial Training of Neural Networks[M]// *Domain Adaptation in Computer Vision Applications*. Cham: Springer International Publishing, 2017: 189-209.
- [23] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal Loss for DENSE Object Detection[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2020, 42(2): 318-327.
- [24] COMSTOCK M C. *Development of Analysis Tools for the Evaluation of Fault Detection and Diagnostics in Chillers*[D]. West Lafayette: Purdue University, 1999.
- [25] ZHAO Chao, SHEN Weiming. Adversarial Mutual Information-guided Single Domain Generalization Network for Intelligent Fault Diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(3): 2909-2918.
- [26] PU Yuanyue, TANG Jian, LI Xuegang, et al. Single-domain Incremental Generation Network for Machinery Intelligent Fault Diagnosis under Unknown Working Speeds[J]. *Advanced Engineering Informatics*, 2024, 60: 102400.

(编辑 王旻玥)

作者简介:高学金,男,1973年生,教授、博士研究生导师。研究方向为关键设备故障诊断、复杂工业过程故障监测理论与应用研究、非线性系统智能建模与智能故障诊断理论与应用。E-mail: gaouxuejin@bjut.edu.cn。高慧慧*(通信作者),女,1991年生,副教授。研究方向为智能数据解析、工业过程安全监控、关键设备健康管理。E-mail: gaohh@bjut.edu.cn。

本文引用格式:

高学金,王璇,姜焜鑫,等. 基于多尺度域生成网络的冷水机组故障诊断[J]. *中国机械工程*, 2026, 37(3): 688-696.

GAO Xuejin, WANG Xuan, JIANG Kexin, et al. Fault Diagnosis of Chillers Based on Multi-scale Domain Generative Networks[J]. *China Mechanical Engineering*, 2026, 37(3): 688-696.