

DOI: 10.19650/j.cnki.cjsi.J2514049

多域对抗迁移的轨道列车转向架故障诊断方法*

楚晓艳¹, 刘星¹, 苗强²

(1. 西南交通大学信息科学与技术学院 成都 610031; 2. 四川大学电气工程学院 成都 610065)

摘要: 轨道列车转向架系统是确保列车运行安全的关键子系统之一, 转向架受线路、时间段、气候条件影响较大, 工况复杂多变, 特定工况故障标签数据少。传统深度学习故障诊断方法通常依赖于大规模标注数据, 且模型在跨域任务中的泛化能力较差; 现有的转向架迁移学习诊断方法普遍缺乏对源域内部特征分布的有效对齐, 增加了负迁移风险, 限制了模型的迁移性能。为缓解上述问题, 故创新地提出了一种多域对抗迁移的轨道列车转向架故障诊断方法, 实现了轨道列车转向架多工况故障特征对齐, 提升了跨工况下的故障诊断性能。首先, 在包含多工况的源域上进行预训练, 预训练过程中使用域对抗融合方法对齐各工况特征, 完成多工况通用特征学习; 随后, 将预训练模型进行部分冻结, 并分别在 20% 和 5% 目标域数据上微调, 完成目标任务适应; 在测试集上对微调完成模型进行测试, 分别取得 98.48%、93.00% 平均分类召回率, 0.13%、0.58% 平均分类误报率, 召回率、误报率、精确率、F1 分数各指标平均值与最差值均高于对比方法。实验表明, 所提方法仅基于易获取的电机三相电流和转速数据, 对动力传动链级联部件的故障诊断准确率更高, 尤其在易混淆故障类型上表现更优; 在目标域数据极少时, 仍可有效利用源域不同工况数据提升诊断准确率。

关键词: 域对抗; 残差网络; 迁移学习; 转向架; 故障诊断

中图分类号: TP206+.3 TH165+.3 **文献标识码:** A **国家标准学科分类代码:** 510.4030

A multi-domain adversarial transfer method for fault diagnosis of railway bogies

Chu Xiaoyan¹, Liu Xing¹, Miao Qiang²

(1. School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031, China;

2. College of Electrical Engineering, Sichuan University, Chengdu 610065, China)

Abstract: The bogie system of a railway train is one of the key subsystems ensuring operational safety. It is significantly affected by factors such as track conditions, time periods, and climate, leading to complex and variable working conditions, while fault-labeled data under specific conditions are scarce. Traditional deep learning-based fault diagnosis methods typically rely on large-scale labeled datasets and often exhibit poor generalization in cross-domain tasks. Existing transfer learning methods for bogie diagnosis generally lack effective alignment of internal feature distributions within the source domain, increasing the risk of negative transfer and limiting the model's transfer performance. To address these issues, this article proposes an innovative multi-domain adversarial transfer method for fault diagnosis of railway bogies, aiming to align fault features of railway bogies under multiple operating conditions and enhance diagnostic performance across domains. First, pretraining is conducted on a source domain that includes multiple operating conditions. During pretraining, a domain-adversarial fusion method is used to align features across different conditions and to learn generalizable features. Then, the pretrained model is partially frozen and fine-tuned on 20% and 5% of the target domain data, respectively, to adapt to the target task. Testing on the test set achieves average classification recall rates of 98.48% and 93.00%, and average false alarm rates of 0.13% and 0.58%, respectively. Across all evaluation metrics—including recall, false alarm rate, precision, and F1-score—both the average and worst-case values outperform comparison methods. Experimental results show that the proposed method achieves higher diagnostic accuracy for faults in the power transmission chain based solely on easily accessible three-phase motor current and rotational speed data. It performs particularly well for confusing fault types and maintains effective diagnostic capabilities even with minimal target

收稿日期: 2025-05-18 Received Date: 2025-05-18

* 基金项目: 中央基础研究培育支持计划理科培育专项(XJ2024001901)项目资助

domain data by leveraging diverse working condition data from the source domain.

Keywords: domain adversarial; residual network; transfer learning; bogie; fault diagnosis

0 引言

随着我国轨道交通运营总里程的增加,列车运行速度的加快,对列车可靠性和安全性有了更高的需求^[1-2]。轨道交通列车的转向架传动系统是列车动力传动的关键组成部分,对其及时准确的故障诊断为列车的智能维护提供了重要依据^[3]。

近年来,深度学习因为无需依赖传统机器学习的专家知识,且具有强大的建模能力和泛化能力,受到广泛关注。深度神经网络能够以自适应的方式从复杂信号中提取故障特征信息,显著提升诊断精度^[4-8];转向架结构复杂、运动状态多变,导致故障诊断准确率低,文献[9]采用胶囊网络(capsule network, CapsNet)实现了端到端的特征自动提取,诊断准确率达96.65%;Huang等^[10]提出了一种基于改进的一维卷积神经网络(1-dimensional convolutional neural network, 1D-CNN)的转向架故障诊断方法,通过提取振动信号的高频分量作为特征,结合1D-CNN深度挖掘故障特征,实现了较高的诊断准确率;Jie等^[11]使用残差-挤压网络(residual-squeeze network, RS-Net)和图注意网络(graph attention network, GAT)构建模型框架,融合并提取特征,从而有效识别转向架故障。上述基于深度学习的诊断方法取得了良好的故障诊断准确率,但其需要大量目标工况故障数据。然而,轨道列车在不同线路、不同时间段、不同气候条件运行均会导致转向架所处的工况变化,单一工况故障数据数量有限,且不同工况故障数据因存在显著分布差异,难以被对齐、利用。如何充分利用已有的多工况数据提升模型在目标任务上的准确率十分重要。

迁移学习可以挖掘源域与目标域间的共享特征表示,可以利用已有不同工况数据中的知识来辅助目标工况下的深度学习任务,为解决目标域数据稀少提供了新的技术路径。文献[12]使用多步联合分布对齐和流形正则化增强了多工况下性能;Shao等^[13]利用预训练网络提取低层次特征,并用标注数据对神经网络微调,取得了优秀的诊断精度;在缺少源域数据情况下,文献[14]使用低成本高保真仿真数据对模型预训练,再引入少量真实样本对模型参数进行微调;基于对齐相关性思路,Qian等^[15]使用卷积自编码器(convolutional autoencoder, CAE)克服特征提取中的输入数据噪声影响并用相关性对齐增强域混淆效果;基于对抗思想,文献[16]使用域对抗神经网络(domain-adversarial neural network, DANN)有效提升了故障诊断模型在跨设备场景中的泛化性,减

少对目标域标注数据数量的依赖;文献[17]使用对抗域自适应训练提升模型迁移能力;文献[18]使用两阶段训练方法将多个源域的数据映射目标任务空间,获得较好故障诊断性能。

针对列车,Du等^[19]提出了一种基于联邦迁移学习的故障诊断方法,提取并融合不同尺度的故障特征,显著提升列车转向架故障的诊断精度;文献[20]提出了一种结合监督式自编码器与卷积神经网络的迁移学习方法,能够在有限变工况下实现轴箱轴承故障的有效识别;Yang等^[21]使用深度对抗混合域自适应网络,提升模型有效性和适用性;Xie等^[22]使用原型聚类子域对抗适应网络,并引入最大均值差异实现源域目标域对齐;Yang等^[23]构建了源域可迁移性预测器,能够自适应地选择源域数据进行迁移学习,提升了诊断的准确性。以上方法在目标域样本较少情况下均有良好的诊断性能,但在处理工况复杂多变的转向架故障诊断问题时仍存在明显局限。部分方法依赖于源域工况较为单一的理想假设,难以适应现实中转向架运行过程中负载、速度、环境温度等工况频繁变化的情况;部分方法虽然引入了多种分布的转向架源域数据,但未充分考虑不同工况下源域内部特征空间的对齐问题,导致模型难以有效提取跨域的共性故障特征,这种特征空间异质性不仅限制了模型在有充足多工况数据时对目标域的故障诊断性能,而且多工况的引入还增加了负迁移的可能性—当源域与目标域的工况差异超过特征映射容忍阈值时,迁移学习反而会削弱模型性能。此外,现有研究多聚焦于少量分类任务,未能充分发挥迁移学习在诸如轨道列车转向架多故障等复杂场景中的潜在优势。

为解决多工况源域数据源域内特征提取未对齐造成模型在目标工况故障诊断能力弱的问题和潜在的负迁移问题,并充分发挥迁移学习在多故障诊断任务中的优势,提出了一种基于多域对抗融合的预训练微调方法(domain-adversarial fusion pretrain finetune, DAF-PFT)用于实现轨道列车转向架故障跨域诊断,主要贡献为:1)提出了一种基于多域对抗的预训练方法,实现了源域中多工况类别特征的有效对齐,增强了特征网络对于共性特征提取能力;2)使用目标域数据对模型微调,进行目标任务二次对齐,微调时各类别数据等量且只有少部分模型参数参与训练,从源头缓解了源域和目标域数据不平衡带来的训练偏差和目标域数据量小带来的过拟合问题;3)结合使用上述两种对齐方法,增加了训练数据利用效率,提升了模型故障诊断性能,验证了迁移学习在复杂多故障(包含级联部件故障)诊断任务中的可行性和应用潜力。

1 基本理论

1.1 预训练-微调

预训练-微调训练范式是迁移深度学习模型已有能力的常见方法,广泛应用在自然语言处理、计算机视觉、大语言模型任务中。首先在数量充足、任务相似的源域数据 D_s 上训练模型参数 θ_p ,随后在目标任务数据 D_t 上对模型微调,目标函数为:

$$\theta_{\beta} = \arg \min_{\theta} \sum_{(x,y) \in D_t} \mathcal{L}(f_{\theta}(x), y) \quad (1)$$

式中: f_{θ} 表示以参数 θ_p 初始化的时序模型; $\mathcal{L}$ 为目标任务的损失函数(如交叉熵)。

预训练-微调实现了从通用时序表征到特定分类任务的知识迁移,迁移过程解耦了通用特征学习阶段和目标任务适应阶段,在数据效率、泛化性、灵活性上显著优于单阶段训练,并且避免了源域与目标域数据量不平衡问题,适合目标数据规模小、跨域的复杂场景。

1.2 域对抗神经网络

深度学习模型的性能依赖于大量数据的支持,目标域 $D_t = \{(\mathbf{x}_t^{(i)}, \mathbf{y}_t^{(i)})\}_{i=1}^{n_t}$ 往往缺乏足够的标注样本,源域 $D_s = \{(\mathbf{x}_s^{(i)}, \mathbf{y}_s^{(i)})\}_{i=1}^{n_s}$ 虽然数据丰富,但与目标域有分布差异,难以直接迁移到目标任务中。

DANN 是一种有效的可减少源域 D_s 与目标域 D_t 特征分布差异的对抗性训练策略^[24]。如图1所示,DANN由特征网络 $G_f = (\mathbf{x}; \theta_f)$ 、域鉴别网络 $G_d = (\mathbf{f}; \theta_d)$ 、分类网络 $G_c = (\mathbf{f}; \theta_c)$ 和梯度反转层 (gradient reversal layer, GRL) 构成。




图1 域对抗神经网络结构

Fig. 1 Domain adversarial neural network architecture

前向传播过程中,如式(2)所示,待分类数据经过特征网络处理后得到特征表示 $\mathbf{f}$ 。GRL 对输入特征 $\mathbf{f}$ 不做变换即 $\mathbf{f}_{out} = \mathbf{f}_{in}$,分类网络 G_c 和域鉴别网络 G_d 对特征 $\mathbf{f}$ 分

别进行目标任务类别、域类别预测,产生分类损失 $\mathcal{L}_c$ 、域鉴别损失 $\mathcal{L}_d$,数学表达式如式(3)、(4)所示,其中 L_c 、 L_d 为损失函数。

$$\mathbf{f} = G_f(\mathbf{x}) \quad (2)$$

$$\mathcal{L}_c = L_c(G_c(\mathbf{f}), \mathbf{y}) \quad (3)$$

$$\mathcal{L}_d = L_d(G_d(\mathbf{f}), \mathbf{d}) \quad (4)$$

反向传播过程中,GRL 将收到的梯度 ∇ 反转,并使用超参数 λ 控制梯度反转强度,如式(5)所示,故各网络参数更新的数学表达式为式(6)~(8),其中 η 为学习率。

$$\nabla \mathbf{f}_{in} = -\lambda \cdot \nabla \mathbf{f}_{out} \quad (5)$$

$$\theta_f \leftarrow \theta_f - \eta \left(\frac{\partial \mathcal{L}_c}{\partial \theta_f} - \lambda \frac{\partial \mathcal{L}_d}{\partial \theta_f} \right) \quad (6)$$

$$\theta_c \leftarrow \theta_c - \eta \frac{\partial \mathcal{L}_c}{\partial \theta_c} \quad (7)$$

$$\theta_d \leftarrow \theta_d - \eta \frac{\partial \mathcal{L}_d}{\partial \theta_d} \quad (8)$$

总的来说,DANN 方法在优化域鉴别网络 G_d 的同时,特征提取器 G_f 被训练成生成使 G_d 难以判别的特征,增强了特征提取器 G_f 对跨域鲁棒特征的提取能力,从而提升了模型的泛化能力。

1.3 残差网络

为了缓解深度神经网络模型在增加深度时伴随的梯度消失和退化问题,特征提取模块采用残差网络(residual neural network, ResNet)架构。ResNet 由 He 等^[25]于2016年提出,引入“残差连接”思想,形成短路路径,构建了直接的信息传播通道,缓解了深度网络训练中的梯度消失、退化问题,有效增加卷积神经网络的深度,且不会引入额外参数,典型残差块由图2所示。




图2 残差块

Fig. 2 Residual block

典型残差块数学表达式为:

$$\mathbf{H}(\mathbf{x}) = \mathbf{f}(\mathbf{x}) + \mathbf{x} \quad (9)$$

式中: $\mathbf{f}(\mathbf{x})$ 为映射关系; $\mathbf{x}$ 为输入; $\mathbf{H}(\mathbf{x})$ 经 Relu 激活后为残差块输出。

2 故障诊断方法

针对轨道列车转向架工况多样,特定工况标签数据少的问题,提出了一种具备跨域泛化能力的故障诊断方

法,整体架构如图3所示,包括特征提取网络 G_f 、多域判别网络 G_d 和故障分类网络 G_c 这3个模块,训练过程分为

“域对抗融合预训练阶段”和“微调阶段”,两个阶段均采用 Adam 优化器优化网络参数。




图3 DAF-PFT方法框架

Fig. 3 Framework of the DAF-PFT method

在预训练阶段,特征提取网络接收来自源域的多工况数据,并通过共享权重参数提取判别特征 f 。所得特征 f 一方面输入至故障分类网络 G_c ,在故障标签的监督下进行分类学习;另一方面则送入多域判别网络 G_d ,通过对抗训练机制最大化判别器的识别误差 $\mathcal{L}_d$,从而最小化不同域间的特征分布差异。该策略有效增强了模型对领域变化的鲁棒性,提升了跨场景下的泛化能力。

在微调阶段,完整复制预训练得到的特征提取网络与故障分类网络参数,冻结除第3级与第4级残差块组中第2个残差块以外的所有特征提取网络参数,仅开放上述2个残差块用于梯度更新,同时保留故障分类网络可训练,以增强模型在目标域的适应能力。该局部层微调策略在保持模型基础表征能力稳定性的同时,赋予网络足够的适应弹性,有效提升其在新领域的故障诊断性能,实现跨域条件下的高准确率识别。

2.1 多域对抗网络

传统的 DANN 方法中,域鉴别器的目标是区分源域样本与目标域样本,因此其损失函数通常采用二元交叉熵 (binary cross-entropy, BCE) 损失来衡量域分类的准确性,二元交叉熵损失函数如式 (10) 所示。

$$\mathcal{L}_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (10)$$

其中, N 为样本数量, y_i 为样本真实标签 (0 或 1), p_i 为模型预测样本标签为 1 的概率。

然而,实际轨道列车转向架源域数据集涵盖了多种工况下的运行数据且包含多个独立分布,若继续使用 BCE 损失将无法准确区分多个工况之间的差异。因此,对 DANN 的损失函数进行了调整,将域二分类任务扩展为域多分类问题,并采用多类交叉熵 (categorical cross-entropy, CCE) 损失函数作为域分类器的优化目标,使其能够区分来自源域 4 种工况的样本,所采用的域分类损失函数形式为:

$$\mathcal{L}_{CCE} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K y_{i,k} \log p_{i,k} \quad (11)$$

式中: K 为源域数; $y_i = (y_{i,1}, \dots, y_{i,K})$ 为第 i 个样本的域标签 one-hot 向量; $p_{i,k}$ 域分类器对样本 i 预测属于第 k 个域的概率。

2.2 域对抗融合预训练

当预训练数据包含轨道列车转向架多种工况时,若采用传统的预训练方法,特征提取网络 $G_f = (x; \theta_f)$ 和故障分类网络 $G_c = (x; \theta_c)$ 仅最小化与任务相关的损失函数 $\mathcal{L}_c = \mathcal{L}(G_c(G_f(x; \theta_f); \theta_c), y)$, 网络更倾向于拟合输入 x 与输出 y 之间的直接关系,忽略了多工况数据之间的共性特征,导致模型更容易在某一类工况数据上过拟合,泛化能力较差。

为缓解这一问题,在预训练阶段引入了域对抗机制。在该机制中,引入一个域判别网络 $G_d = (f; \theta_d)$,用于区分输入特征来自的具体工况(即域标签 d)。同时,通过添加一个域判别损失函数 $\mathcal{L}_d = \mathcal{L}_{CCE}(G_d(f), d)$,并通过梯度反转层进行反向传播,使得特征网络在训练时需同时最小化主任务损失 $\mathcal{L}_c$ 并最大化域判别损失 $\mathcal{L}_d$ 。最终目标函数可表示为:

$$\min_{\theta_f, \theta_c} \max_{\theta_d} \mathcal{L}_{\text{total}} = \mathcal{L}_c(G_c(G_f(\mathbf{x}; \theta_f); \theta_c), \mathbf{y}) - \lambda \mathcal{L}_d(G_d(G_f(\mathbf{x}; \theta_f); \theta_d), d) \quad (12)$$

式中: λ 为调节域对抗强度的超参数,且训练过程 λ 计算方法如式(13)。

$$\lambda(n_{\text{iter}}) = 5 \tanh\left(\frac{n_{\text{iter}}}{1000} - 5\right) + 5 \quad (13)$$

式中: n_{iter} 为迭代次数。

这种对抗训练使得特征提取网络更倾向于学习与域无关的通用特征,降低了其对特定工况数据的过拟合风险,从而提升了模型在多工况数据上的泛化能力。

2.3 评价指标

为了衡量所提算法的性能,从多维度评估指标体系对模型性能进行量化分析,采用了多种评价指标,包括召回率(true positive rate, TPR)、误报率(false positive rate, FPR)、精确率(Precision)和F1分数(F1-Score),计算公式为:

$$TPR = \frac{TP}{TP + FN} \quad (14)$$

$$FPR = \frac{FP}{FP + TN} \quad (15)$$

$$Precision = \frac{TP}{TP + FP} \quad (16)$$

$$F1 = 2 \times \frac{Precision \times TPR}{Precision + TPR} \quad (17)$$

式中: TP (真正例)、 TN (真负例)、 FP (假正例)和 FN (假负例)分别表示模型预测结果与真实标签之间的4种基本匹配情况。

这些指标从不同维度反映模型的故障诊断能力: TPR 衡量模型正确识别正例的能力; FPR 反映模型将负例误判为正例的比例; $Precision$ 评估模型预测为正例的样本中真实正例的比例; $F1$ 分数为精确率与召回率的调和平均数。

3 实验结果与分析

3.1 数据集介绍

本研究验证所用的转向架数据集来源于北京交通大学先进轨道自主运行全国重点实验室^[26]构建的地铁列车转向架传动系统故障模拟实验台。该实验台,如图4所示,以真实地铁转向架为原型,按1:2小缩比设计,能较好模拟受力状态、振动特性等,有较好的工程代表性和真实性,其单条动力传动链由三相异步交流电机驱动,经减速齿轮箱传递至轴箱;通过变频器可精确调控电机转速(20、40、60 Hz),并采用液压加载装置施加 ± 10 kN及0 kN共3种横向负载,形成9种工况组合(3转速 $\times$ 3负载)。




图4 地铁列车转向架传动系统故障模拟实验台

Fig. 4 Fault simulation test bench for metro train bogie transmission system

实验过程中同步采集了涵盖传动系统全链路状态的多模态传感器数据,包含转速、声音、三轴振动及三相电流等24通道信号(CH1~CH24),所有通道采样频率统一为64 kHz。该数据集共包含52种设备健康状态,具体涵盖

1种正常状态、4种电机单一故障、8种齿轮箱单一故障、5种轴箱单一故障、10种多部件复合故障以及24种系统级关联复合故障,为轨道交通关键设备智能诊断研究提供了接近实际运行工况的多维度、高精度的实验数据支持。

3.2 跨域故障诊断实验设置

在跨域故障诊断实验设置方面,源域选取4种典型工况:40 Hz/+10 kN、60 Hz/+10 kN、40 Hz/-10 kN 和 60 Hz/-10 kN;目标域选择与源域电机转速和负载均不同的新型工况:20 Hz/0 kN,使源域与目标域差异最大化,以模拟实际中常见的工况迁移场景,验证模型的泛化能力。

输入信号方面,选用 CH7 至 CH10 共4个通道的时

序数据作为模型输入。其中,CH7~CH9 分别对应牵引电机三相电流信号,CH10 表示牵引电机转速信号。为提升诊断系统部署的便捷性,未引入需额外布置的声传感器数据或加速度计数据。故障类型包括电机与齿轮箱的单一故障及其无故障状态,故障状态(见图5)及其编号为:正常状态(M0G0),即无故障情况;齿轮箱的8种单一故障(G1~G8);电机的4种单一故障(M1~M4)。




图5 齿轮箱/电机故障件图片

Fig. 5 Images of faulty gearbox/motor components

图3中故障分类网络 G_c 分类标签设定如下:类别0对应M0G0,类别1~8依次对应G1~G8,类别9~12依次对应M1~M4。该多类别设置不仅检验模型对电机自身故障的识别能力,也评估其对与电机级联的齿轮箱故障的诊断效果,从而更全面地反映方法在复杂系统中的适用性。

3.3 数据预处理

针对源域与目标域数据,具体预处理流程为:

1) 标准化处理:为消除不同通道之间信号量纲的差异,对每个通道的原始时域信号分别进行标准化处理。采用 StandardScaler 方法对数据进行归一化操作,如式(18)所示。

$$x' = \frac{x - \mu}{\sigma} \quad (18)$$

其中, μ 为样本均值, σ 为标准差。

2) 滑动窗口分割:将标准化后的信号按滑动窗口方式进行分割,窗口长度设置为1024个采样点。考虑到目标域数据样本量较少,为提高数据利用率,采用128个采样点作为步长进行滑动采样;源域数据样本充足,为平衡数据总量与后续模型训练效率,设置步长为256个采样点。每个分割出的窗口分别标注对应的工况类别和故障类别标签,以支持后续监督学习任务。

3) 数据集划分:源域数据全部作为训练集使用,不

置验证集、测试集;目标域训练集样本按时间顺序选取,保证训练数据与测试数据的时空隔离;剩余目标域数据采用随机抽样方式分为目标域验证集和目标域测试集。

3.4 实验结果及分析

为验证所提出 DAF-PFT 方法的有效性,设计了6种方法作为对比实验,即:1) 多任务学习^[27] (multitask learning, MTL),通过在4种源域工况和一种目标工况的混合数据中使用特征网络和分类网络进行监督学习,提取各类别的共有特征以提升测试集上的准确率,该方法未考虑域间分布差异,主要验证多工况联合训练对模型泛化性的基础影响;2) 深度域混淆方法^[28] (deep domain confusion, DDC),通过引入域混淆损失函数,使模型能够学习到域无关的判别性特征;3) 基于反向传播的开集域自适应方法^[29] (open set domain adaptation by backpropagation, OSDABP),该方法通过联合优化源域分类损失和对抗性域适应损失,与 DANN 相似,但只对模型认为属于源域“已知类别”的目标域样本进行域对齐;4) 域对抗神经网络 (DANN),作为域对抗单阶段训练对比方法;5) 直接训练 (direct train, DT),即仅在目标域的训练数据上进行监督学习,不进行任何迁移,作为非迁移学习的基准;6) 预训练微调方法 (pretrain-finetune, PFT),即先在源域数据上进行监督预训练,然后将特征提取网络和分类器迁移到目标域进行微调,作为所提方法的消

融对照实验(即去除了预训练阶段中的多域融合过程)。所有方法均在 PyTorch 深度学习框架下实现,训练时统一设置批量大小为 512,学习率为 0.001,最大(预)训练次数为 100 次,最大微调次数为 15 次(DAF-PFT、PFT 方法),以确保实验条件一致,便于性能比较。

图 6 展示了各模型在测试集上的各分类召回率对比




图 6 各方法故障召回率

Fig. 6 Bar chart of fault recall rates for various methods

表 1 展示了 7 种模型在测试集上的故障诊断综合性能。所提出的 DAF-PFT 方法在所有评价指标平均值均达到最优水平,其中平均召回率达到 98.48%,误报率低至 0.13%。

从子类别分析发现:DANN、DDC 和 OSDABP 3 种基于域对齐的方法通过特征空间对齐策略在电机故障(类别 11、12)诊断中相较 DT 实现了显著提升,召回率接近 100%。然而,这些方法在齿轮箱故障迁移任务中表现出明显的局限性,部分类别出现负迁移,OSDABP 虽然引入了特征选择性对齐机制,仅对那些被模型认为属于源域“已知类别”的目标域样本进行域对齐,但未能避免迁移后性能下降,可能是因为单纯依赖二阶统计量匹配(如 DDC 的协方差对齐)或对抗学习(如 DANN、OSDABP 的梯度反转层)难以对所有训练数据建立精确的跨域特征映射关系。MTL 多任务框架通过参数共享机制在类别 2、3、6、8 上取得显著提升,但其共享表征学习机制存在缺陷,共享特征提取器容易产生负迁移效应,如类别 7 召回率骤降至 16.22%。PFT 方法平均召回率较高,但在类别 3 的召回率较差,低于 MTL 和所提方法,这暴露了其在级联部件故障识别中的局限性:模型未建立准确的跨工况知识,难以精确区分级联部件故障信号。

进一步分析发现,DANN、DDC、OSDABP、MTL 在电机故障迁移中表现优异的根本原因在于:故障诊断模型

情况。从图 6 中可见,所提出的 DAF-PFT 方法在 7 种模型中的平均召回率最高,PFT 和 MTL 方法次之。不同模型在召回率上的差异主要体现在对正常状态(类别 0)和齿轮箱故障(类别 1~8)的识别效果上;而在电机故障(类别 9~12)的识别中,除 DT 方法外,其余模型均表现出较高的召回率。

输入的 4 通道时序信号主要反映电机本体状态,与分类任务存在强相关性。此时,域对齐策略能够有效挖掘源域中的判别特征(如电机故障特征频率、幅值)。但在齿轮箱故障诊断任务中,输入信号与目标故障的相关性显著减弱,导致源域知识迁移产生干扰效应:DANN 等方法的域对齐过程会过度压缩特征空间,造成齿轮箱故障特征的信息损失;MTL 框架的共享参数更新过程被电机故障样本主导,抑制了齿轮箱特异性特征的学习。所提出的 DAF-PFT 方法通过两阶段对齐技术突破了上述瓶颈,能够有效提取共性特征,并迁移源域知识至目标域,可以更好地完成故障诊断任务。

3.5 结果可视化分析

为直观展示 DAF-PFT 方法对域融合的有效性,利用训练完成模型的特征提取网络对测试集样本进行高维特征表征,随后将高维特征用采用 t 分布随机邻域嵌入(t-distribution stochastic neighbor embedding, t-SNE)算法降维到二维平面,图 7 展示了 7 种方法的特征网络所提取特征的可视化结果,不同形状或颜色均代表不同类别。

由图 7 可知,DANN、DDC、DT、MTL 及 OSDABP 法均出现类别特征的大范围重叠现象,原因是 DANN、DDC、MTL、OSDABP 等方法因过度强调领域对齐或任务相关性,而忽略了类别间的分离性约束,导致类别特征区分性差,干扰了分类网络的判别过程,使故障诊断准确率显




图 7 各方法特征可视化

Fig. 7 Visualization of features from different methods

著降低。PFT 方法虽然有效缓解了特征空间的大面积重叠问题,将重叠区域控制在特征分布边缘,然而缺乏源域内多工况对齐,未能分离类别 0 和 3 的特征表示,导致类别 3 分类召回率显著低于所提方法 (77.33%,所提方法 96.95%);DAF-PFT 方法不存在特征大范围重叠问题,仅在类别 0 和 3、4 和 8、6 和 7 (均为齿轮箱故障)存在边缘重叠,对分类准确率影响较小。DAF-PFT 方法平衡了特征可分性与工程实用性,在保持模型输入数据 (电机三相电流值、转速) 采集便捷的基础上,实现了较好的特征可分离性。对比多种迁移学习方法,DAF-PFT 在提升特征可分性和分类性能方面具有显著优势。

为进一步验证 DAF-PFT 方法的有效性,使用混淆矩阵 (如图 8) 对 DAF-PFT 及其两种关联方法的诊断结果进行分析。

图 8 中,横纵坐标分别对应预测标签和真实标签,主对角线元素反映各类别召回率。由图 8 可以看出,3 种方法均可有效识别电机故障,DANN 对正常状态和齿轮箱故障诊断效果较差,将 97.3% 齿轮磨损故障检测为轴承保持架故障。对混淆矩阵进行进一步分析可以看出,





图 8 分类结果混淆矩阵 (测试集)

Fig. 8 Confusion matrices (test set)

所有方法均将齿轮缺齿误报为正常状态,其原因在于缺齿故障特征与正常磨损特征相似;同时,所有方法也均将

轴承保持架故障误报为齿轮断齿,原因可能是由于轴承保持架故障与齿轮断齿都能引起周期性冲击,导致特征混淆。然而,相比于 DANN 和 PFT,DAF-PFT 仅将 7.7% 的轴承保持架故障诊断为齿轮断齿故障,其他故障均被较好识别(召回率高于 96%),充分证明所提方法泛化性能良好。

3.6 微调数据量与预训练回合数敏感性分析

为了分析微调数据量对 DAF-PFT 与 PFT 方法的影响,分别使用两种方法对应的预训练模型,并仅采用目标

数据的 5% 进行微调。各项指标如表 2 所示。实验结果表明,在微调数据量减少了 75% 的情况下,所提 DAF-PFT 方法与对比方法的召回率均有所下降,但 DAF-PFT 的召回率降幅相对更小。DAF-PFT 的平均召回率达到 93.00%,优于 PFT 的 91.36%;在子类别中最低召回率方面,DAF-PFT 也以 74.7% 高于 PFT 的 65.8%。此外,在其余各项评价指标的平均值及其子类别的最差值,DAF-PFT 均优于 PFT 方法。上述结果表明,DAF-PFT 在低数据量微调场景下仍能保持良好的泛化能力与鲁棒性。

表 2 5% 目标域数据微调模型测试集结果

Table 2 Performance of models fine-tuned using 5% target domain data (test set)														
指标	方法	类别 0	类别 1	类别 2	类别 3	类别 4	类别 5	类别 6	类别 7	类别 8	类别 9	类别 10	类别 11	类别 12 平均值
召回率	DAF-PFT	0.874 4	0.999 0	0.991 0	0.837 3	0.801 8	0.942 9	0.936 4	0.989 0	0.747 2	1.000 0	1.000 0	0.987 5	0.984 0 0.930 0
	PFT	0.715 2	0.996 5	0.973 5	0.658 2	0.922 4	0.841 3	0.949 4	0.969 5	0.871 9	0.994 5	0.990 0	0.996 5	0.998 5 0.913 6
误报率	DAF-PFT	0.013 2	0.005 6	0.000 9	0.010 5	0.020 3	0.000 7	0.001 2	0.005 4	0.017 1	0.000 0	0.000 8	0.000 0	0.000 0 0.005 8
	PFT	0.026 0	0.013 3	0.000 2	0.023 4	0.011 1	0.000 5	0.002 6	0.006 1	0.008 7	0.000 0	0.000 1	0.000 5	0.001 1 0.007 2
精确率	DAF-PFT	0.846 4	0.937 1	0.989 0	0.869 5	0.766 9	0.991 1	0.984 7	0.938 3	0.784 6	1.000 0	0.990 1	1.000 0	1.000 0 0.930 6
	PFT	0.696 4	0.861 5	0.997 9	0.701 0	0.873 5	0.993 5	0.968 4	0.929 9	0.893 3	1.000 0	0.998 5	0.994 0	0.987 1 0.915 0
F1 分数	DAF-PFT	0.860 2	0.967 1	0.990 0	0.853 1	0.783 9	0.966 4	0.960 0	0.963 0	0.765 4	1.000 0	0.995 0	0.993 7	0.991 9 0.930 0
	PFT	0.705 7	0.924 1	0.985 6	0.678 9	0.897 3	0.911 1	0.958 8	0.949 3	0.882 5	0.997 2	0.994 2	0.995 3	0.992 8 0.913 3

为了分析预训练回合数对模型诊断能力的影响,绘制了 DAF-PFT 与 PFT 的模型在不同预训练回合后微调的性能表现折线图如图 9 所示,横坐标为模型的预训练回合数,纵轴为微调训练的最高验证集平均召回率。




图 9 预训练回合敏感性折线图

Fig. 9 Training epoch sensitivity line charts

从图 9 可以看出,在使用 20% 目标域数据微调时,所提方法在 20 个预训练回合前召回率提升速度慢于预训练微调方法,这是因为 DAF-PFT 预训练存在域对抗融合过程,梯度在某些维度存在抵消,降低了预训练速度;在两种目标域数据量微调时,DAF-PFT 均在 30、35、60 预训

练回合数达到较高召回率,表明微调效果依赖预训练模型质量,充分说明了 DAF-PFT 中的域对抗融合预训练方法对提升预训练模型泛化能力的有效性。

3.7 模型实时性能分析

为了验证所提 DAF-PFT 方法的训练灵活性与推理实时性,本小节使用 Intel Xeon@2.00 GHz 双核、Nvidia T4 平台,对各模型的 CPU 推理耗时、GPU 推理耗时及训练耗时进行了测试,结果见表 3。推理时间是 Batch Size 为 1 时测量结果;训练时间使用 20% 目标域数据训练测得,对于 DAF-PFT 和 PFT 方法,训练时间为微调训练耗时。

表 3 模型训练、推理实时性能

Table 3 Training and inference time of models (s)			
方法	CPU 推理时间	GPU 推理时间	训练时间
DAF-PFT	0.016 213	0.006 022	31
PFT	0.016 263	0.006 069	35
DDC	0.016 419	0.006 184	860
DT	0.016 531	0.006 187	566
MTL	0.016 501	0.006 123	901
DANN	0.017 267	0.006 390	853
OSDABP	0.016 239	0.006 231	844

从表3可知,推理时间仅在不同硬件上差异显著,这是由于各方法模型架构相同,推理时间用GPU时可达毫秒级,而使用CPU时亦在十毫秒级;PFT和所提DAF-PFT方法对目标域适应仅需进行微调训练,显著提升了训练效率,其训练时间低于其他方法90%以上。综上,所提DAF-PFT方法在推理时对加速硬件要求较低,可实现较高检测频率并降低了部署复杂度;其在适应目标域时所需的短暂训练时间,为实时变工况故障检测提供了可能。

4 结 论

针对目标域健康状态数据较少时故障诊断的准确率低、现有的迁移学习方法普遍缺乏对源域内部多工况的有效对齐和源域多工况数据可能造成模型负迁移的问题,提出了一种多域对抗迁移的轨道列车转向架故障诊断方法。该方法使用预训练和微调两阶段训练范式,缓解了单训练阶段方法(DANN, DDC, OSDABP)易受源域目标域鸿沟影响的问题,避免了源域与目标域数据量不匹配问题。此外,通过在预训练阶段引入域对抗融合技术,使特征网络对齐不同工况下的同类别特征,进一步提升了特征网络对共性特征的提取,有效减少了目标域的特征混叠,使模型拥有更优秀的泛化能力和较高的故障诊断准确率。在BJTU-RAO转向架公开数据集上,与目前主流的域自适应对齐方法相比,DAF-PFT方法对源域的泛化特征提取能力更强、受源域不同工况对齐鸿沟影响更小,在多故障任务上准确率提升较大;相比消融对比实验PFT,DAF-PFT在易混淆分类上提取了更准确的共性特征,故障诊断表现更好。在极低目标域数据(5%)训练上,得益于对源域多工况特征充分学习和融合,DAF-PFT对比PFT在平均准确率和最低准确率仍具有较大优势。此外,DAF-PFT方法具有较强的可行性,仅需在预训练阶段进行轻微调整即可引入对抗域融合机制,操作层面具有高度可实施性。当源域数据保持不变时,无需重复进行预训练,从而有效减少了计算开销,提升了方法的应用效率与实用性。

尽管所提方法在目标域数据量较少时能有效地利用多工况数据迁移学习,有效提升了故障诊断准确率,但所提方法在预训练过程中使用的数据均带有类标签,实际生产过程中产生的大量数据不带有类标签,且缺少类标签对于域融合对抗过程影响较小,因此可以在所提方法上引入混合数据(有类标签和无标签)进行预训练,从而在控制标注成本时获得相近的域融合效果。此外,在源域数据丰富时可以使用预设更少的架构配合扩展法则进一步提升诊断性能。

参考文献

- [1] 冯爱军. 中国城市轨道交通2021年数据统计与发展分析[J]. 隧道建设(中英文), 2022, 42(2):336-341.
 - [2] 潘昭宇. 都市圈轨道交通网络规划研究综述及展望[J]. 铁道运输与经济, 2024, 46(10):61-72.
 - [3] 杨绍普, 顾晓辉, 刘永强, 等. 转向架关键运动部件动力学机理与故障诊断研究综述[J]. 机械工程学报, 2023, 59(20):225-243.
 - [4] 乔卉卉, 赵二贤, 郝如江, 等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报, 2024, 45(9):120-130.
 - [5] 张宇鹏, 邱常卿, 田煜, 等. 基于混合倒谱与LSTM网络的轴承故障诊断[J]. 组合机床与自动化加工技术, 2023(6):87-92.
 - [6] LONG J Y, CHEN Y B, YANG ZH, et al. A novel self-training semi-supervised deep learning approach for machinery fault diagnosis[J]. International Journal of Production Research, 2023, 61(23):8238-8251.
 - [7] 陈义鹏, 徐志强, 钟杰, 等. 基于时空自注意力的航天器电源系统故障诊断[J]. 电子测量技术, 2024, 47(7):184-191.
- FENG AI J. Data statistics and development analysis of urban rail transit in China in 2021[J]. Tunnel Construction, 2022, 42(2):336-341.
- PAN ZH Y. Overview and prospect of urban rail transit network planning research[J]. Railway Transport and Economy, 2024, 46(10):61-72.
- YANG SH P, GU X H, LIU Y Q, et al. Review of dynamic mechanism and fault diagnosis for key rotating components of bogies[J]. Journal of Mechanical Engineering, 2023, 59(20):225-243.
- QIAO H H, ZHAO ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions[J]. Chinese Journal of Scientific Instrument, 2024, 45(9):120-130.
- ZHANG Y P, QIU CH Q, TIAN Y, et al. Bearing fault diagnosis based on hybrid multi-cepstrum and LSTM network[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2023(6):87-92.
- CHEN Y P, XU ZH Q, ZHONG J, et al. Spacecraft power system fault diagnosis based on spatio-temporal

- self-attention[J]. *Electronic Measurement Technology*, 2024, 47(7):184-191.
- [8] 庞荣,余志斌,熊维毅,等. 基于深度学习的高速列车转向架故障识别[J]. *铁道科学与工程学报*, 2015, 12(6):1283-1288.
- PANG R, YU ZH B, XIONG W Y, et al. Faults recognition of high-speed train bogie based on deep learning[J]. *Journal of Railway Science and Engineering*, 2015, 12(6):1283-1288.
- [9] CHEN L L, QIN N, DAI X, et al. Fault diagnosis of high-speed train bogie based on capsule network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(9):6203-6211.
- [10] HUANG D Q, LI SH P, QIN N, et al. Fault diagnosis of high-speed train bogie based on the improved-CEEMDAN and 1-D CNN algorithms[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70:3047922.
- [11] JIE M, DONG H H, JIA L M, et al. An adaptive multisensor fault diagnosis method for high-speed train bogie[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(6):6292-6306.
- [12] 陈仁祥,朱玉清,胡小林,等. 自适应正则化迁移学习的不同工况下滚动轴承故障诊断[J]. *仪器仪表学报*, 2021, 41(8):95-103.
- CHEN R X, ZHU Y Q, HU X L, et al. Fault diagnosis of rolling bearing under different working conditions using adaptation regularization based transfer learning[J]. *Chinese Journal of Scientific Instrument*, 2021, 41(8):95-103.
- [13] SHAO S Y, MCALEER S, YAN R Q, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(4):2446-2455.
- [14] 苗建国,李茂银,邓聪颖,等. 非理想数据下基于仿真数据辅助迁移学习的滚动轴承故障诊断[J]. *仪器仪表学报*, 2023, 44(4):28-39.
- MIAO J G, LI M Y, DENG C Y, et al. Rolling bearing fault diagnosis for non-ideal dataset based on finite element simulation and transfer learning[J]. *Chinese Journal of Scientific Instrument*, 2023, 44(4):28-39.
- [15] QIAN Q, QIN Y, WANG Y, et al. A new deep transfer learning network based on convolutional auto-encoder for mechanical fault diagnosis[J]. *Measurement*, 2021; 178:109352.
- [16] WANG Q, MICHAU G, FINK O. Domain adaptive transfer learning for fault diagnosis[C]. 2019 Prognostics and System Health Management Conference, 2019:279-285.
- [17] 文利燕,陈金陵,姜斌,等. 基于联合对抗域自适应网络的跨工况故障诊断方法[J]. *控制与决策*, 2025, 40(5):1503-1511.
- WEN L Y, CHEN J L, JIANG B, et al. A joint adversarial domain adaptive network based cross working conditions fault diagnosis method[J]. *Control and Decision*, 2025, 40(5):1503-1511.
- [18] 谢刚,韩秦,聂晓音,等. 基于两阶段域泛化学习框架的轴承故障诊断方法[J]. *自动化学报*, 2024, 50(11):2271-2285.
- XIE G, HAN Q, NIE X Y, et al. A two-stage domain generalization learning framework for fault diagnosis of bearings[J]. *Acta Automatica Sinica*, 2024, 50(11):2271-2285.
- [19] DU J H, CHENG J Q, YOU Y T, et al. Federated transfer learning for fault diagnosis of high-speed train bogie with data security and training optimization[C]. 2023 CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes, 2023:1-6.
- [20] 罗宏林,柏林,侯东明,等. 有限变工况特征迁移学习方法及其在高速列车轴箱轴承故障诊断中的应用[J]. *仪器仪表学报*, 2022, 43(3):132-145.
- LUO H L, BO L, HOU D M, et al. A transfer learning method for bearing fault diagnosis under finite variable working conditions and its application in train axle-box bearings fault diagnosis[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(3):132-145.
- [21] YANG B Y, WANG T T, XIE J S, et al. Deep adversarial hybrid domain-adaptation network for varying working conditions fault diagnosis of high-speed train bogie[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72:3276007.
- [22] XIE J S, WANG SH J, LI Y Y, et al. A simulated-to-real transfer fault diagnosis method based on prototype clustering subdomain adversarial adaptation network for HST bogie bearing[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73:3451585.
- [23] YANG B Y, WANG T T, XIE J S, et al. A source

domain adaptive method for transfer-learning-based fault diagnosis of train bogie bearings at higher speeds [J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74:3541687.

[24] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. Journal of Machine Learning Research, 2016, 17(59):1-35.

[25] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016:770-778.

[26] DING AO, QIN Y, WANG B, et al. Evolvable graph neural network for system-level incremental fault diagnosis of train transmission systems [J]. Mechanical Systems and Signal Processing, 2024, 210:111175.

[27] CARUANA R. Multitask learning [J]. Machine Learning, 1997, 28(1):41-75.

[28] TZENG E, HOFFMAN J, ZHANG N, et al. Deep domain confusion:Maximizing for domain invariance [J]. ArXiv preprint arXiv:1412.3474, 2014.

[29] SAITO K, YAMAMOTO S, USHIKU Y, et al. Open set domain adaptation by backpropagation [C]. Computer Vision-ECCV 2018, 2018:156-171.

作者简介



楚晓艳,2012 年于河南科技学院获得学士学位,2015 年于重庆交通大学获得硕士学位,2019 年于中南大学获得博士学位,现为西南交通大学信息科学与技术学院助理研究员,主要研究方向为多电机系统故障预测及健康管理、分布式控制、故障诊断和容错控制。

E-mail:xyanchu@swjtu.edu.cn

Chu Xiaoyan received her B. Sc. degree from Henan Institute

of Technology in 2012, received her M. Sc. degree from Chongqing Jiaotong University in 2015, and received her Ph. D. degree from Central South University in 2019. She is currently an assistant research fellow at Southwest Jiaotong University. Her main research interests include fault prediction and health management of multi-motor systems, distributed control, fault diagnosis, and fault-tolerant control.



刘星,2022 年于南京工业大学获得学士学位,现为西南交通大学控制理论与控制工程专业硕士研究生,主要研究方向为故障诊断、迁移学习。

E-mail:xl2025@my.swjtu.edu.cn

Liu Xing received his B. Sc. degree from Nanjing Tech University in 2022. He is currently a master student in the Control Theory and Control Engineering at Southwest Jiaotong University. His main research interests include fault diagnosis, and transfer learning.



苗强(通信作者),1998 年于北京航空航天大学获得学士学位,2001 年于北京航空航天大学获得硕士学位,2005 年于多伦多大学获得博士学位,现为四川大学电气工程学院教授,博士生导师,主要研究方向为重大装备故障诊断、健康评估以及可靠性研究。

E-mail:mqiang@scu.edu.cn

Miao Qiang (Corresponding author) received his B. Sc. degree from Beijing University of Aeronautics and Astronautics in 1998, received his M. Sc. degree from Beijing University of Aeronautics and Astronautics in 2001, and received his Ph. D. degree from University of Toronto in 2005. He is currently a professor at Sichuan University. His main research interests include equipment fault diagnosis, health assessment and reliability.