

DOI: 10.13382/j.jemi.B2205598

# 基于联合分布偏移差异的跨域滚动轴承故障诊断方法\*

雷杨博<sup>1</sup> 朱智勤<sup>1</sup> 柴毅<sup>2</sup> 齐观秋<sup>3</sup> 安翼尧<sup>2</sup> 徐鹏<sup>1</sup>

(1. 重庆邮电大学自动化学院 重庆 400065; 2. 重庆大学自动化学院 重庆 400030;

3. 布法罗州立学院计算机信息系统系 美国纽约 14222)

**摘要:** 现有的无监督域自适应故障诊断方法大多只基于单一域信号实现,提取的故障信息不够全面。只注重实现源域和目标域特征的边缘分布对齐,忽略了样本的条件分布差异,限制了诊断精度的提升。为克服以上问题,提出一种基于联合分布偏移差异(joint distribution offset difference, JDOD)的跨域滚动轴承故障诊断方法。使用两个结构一致的卷积神经网络(CNN)分别提取信号的时域与频域特征,获取更完整的故障信息。提出联合分布偏移差异,实现不同域特征的边缘分布对齐和条件分布对齐。在两个多工况轴承数据集上与多种先进方法展开对比实验,取得了99%以上的平均诊断精度。实验结果表明联合分布偏移差异有效提升了跨域故障精度。

**关键词:** 跨域故障诊断;域自适应;分布对齐;卷积神经网络

**中图分类号:** TN10;TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460

## Cross-domain fault diagnosis method of rolling bearings based on joint distribution offset difference

Lei Yangbo<sup>1</sup> Zhu Zhiqin<sup>1</sup> Chai Yi<sup>2</sup> Qi Guanqiu<sup>3</sup> An Yiyao<sup>2</sup> Xu Peng<sup>1</sup>

(1. School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. School of Automation, Chongqing University, Chongqing 400030, China; 3. Computer Information Systems Department, Buffalo State College Buffalo, NY 14222, USA)

**Abstract:** Most of the existing unsupervised domain adaptive fault diagnosis methods are only implemented based on a single domain signal, and the extracted fault information is not comprehensive enough. Only focus on realizing the edge distribution alignment of source and target domain features, ignoring the conditional distribution differences of samples, which limits the improvement of diagnostic accuracy. To overcome the above problems, a cross-domain fault diagnosis method of rolling bearings based on joint distribution offset differences (JDOD) is proposed. Two structurally consistent CNNs are used to extract the time-domain and frequency-domain features of the signal respectively to obtain more complete fault information. Joint distribution offset difference is proposed to realize edge distribution alignment and conditional distribution alignment of different domain features. Comparing experiments with various advanced methods on two multi-condition bearing datasets, the average diagnostic accuracy of more than 99% is obtained. The experimental results show that the joint distribution offset difference effectively improves the cross-domain fault diagnostic accuracy.

**Keywords:** cross-domain fault diagnosis; domain adaptation; discrepancy alignment; CNN

## 0 引言

现代工业中,设备各个组件之间存在复杂的交互关

系,局部故障很可能传递到整个生产链从而导致严重事故。为了尽早地发现和排除故障从而消除隐患,对于滚动轴承的故障诊断尤为重要。故障诊断的方法可大致分为3类:基于动力学模型、基于信号分析和基于数据驱

收稿日期: 2022-06-18 Received Date: 2022-06-18

\* 基金项目: 国家自然科学基金(61803061, 61906026)、重庆市教委重庆市高校创新群体“成渝双城经济圈建设”科技创新项目(KJCXZD2020028)、重庆市技术创新与应用发展专项(cstc2019jcsx-zdtx0068)项目资助

动<sup>[1-2]</sup>。其中,数据驱动的方法由于降低了对专家经验和知识的依赖,能够取得较高的诊断精度而发展迅速。近年来,随着深度学习的快速崛起,基于深度学习的滚动轴承故障诊断研究也被大量发表<sup>[3-7]</sup>。然而,许多深度学习故障诊断研究都建立在两个前提之下:1)标注数据充足可靠;2)训练集(源域)和测试集(目标域)数据属于相同的分布。在实际工业场景中,由于设备长期处于正常工作状态,目标域数据往往在新的工作条件下被收集,难以及时地获取大量标注数据。此外,设备的更换,工作条件如转速、载荷改变都会引发数据分布偏移,这将会导致在源域训练的模型在目标域上的诊断性能严重下降。

一些方法<sup>[8-10]</sup>采用参数迁移方法,能够降低对目标域标注数据的需求,但是如果目标域没有标注数据,则需要无监督跨域故障诊断策略。为此,Guo 等<sup>[11]</sup>、Zhang 等<sup>[12]</sup>、Li 等<sup>[13]</sup>、Jin 等<sup>[14]</sup>和 Jiao 等<sup>[15]</sup>提出了基于最大平均差异(maximum mean discrepancy, MMD)和域对抗自适应的跨域故障诊断方法。Li 等<sup>[16]</sup>提出一种基于熵的迁移学习方法。胡若晖等<sup>[17]</sup>通过 DCGAN 对少量样本进行模式式扩充,并且利用域对抗自适应来促进学习域不变特征。上述无监督域自适应故障诊断方法取得了不错的结果,但是大多忽略了样本的类间差异即条件分布差异。这可能导致处于不同类别子域边界的样本被错误分类<sup>[18-20]</sup>。

为了兼顾边缘分布对齐和条件分布对齐,实现高精度的跨域滚动轴承故障诊断,提出一种基于联合分布偏移差异(joint discrepancy offset difference, JDOD)的智能诊断模型,分别从特征提取和分布对齐两个方面进行改

进。利用两条基于卷积神经网络(convolutional neural network, CNN)构造的特征提取支路分别提取时域和频域特征,再进行叠加得到融合特征,以获取丰富互补的诊断信息<sup>[21-22]</sup>。不同于施加特征级条件分布对齐约束,本文提出自适应局部最大平均差异,动态地调整域间不同类别的局部 MMD 距离实现条件分布的对齐。同时利用全局 MMD 来实现边缘分布对齐,利用域对抗自适应将源域与目标域特征投影到相同的高维空间,改善特征分布距离,增强模型的域自适应能力。利用相同结构的特征提取网络结合不同的域自适应策略组成不同跨域故障诊断方法,开展对比实验。验证了联合分布偏移差异对跨域故障诊断精度的提升作用。

### 1 基于联合分布偏移差异的故障诊断

图 1 展示了所提出的跨域诊断模型及其训练过程。将振动信号及其频谱分别输入两个独立且结构相同的特征提取模块,并将提取的时域特征和频域特征组合得到融合特征。计算源域的融合特征和目标域的融合特征的最大平均差异 MMD 和自适应局部最大平均差异(adaptative local maximum mean discrepancy, ALMMD),采用域鉴别器计算源域与目标域融合特征间的域对抗损失,使用源域数据的分类结果及其标签计算故障分类损失。利用总损失  $L$ 、分类器损失  $L_{Cls}$ 、分布偏移损失  $L_{MMD}$  与  $L_{ALMMD}$  以及域鉴别器损失  $L_{Dis}$ ,更新特征提取模块、分类器和域鉴别器的参数以及 ALMMD 的自适应权重。

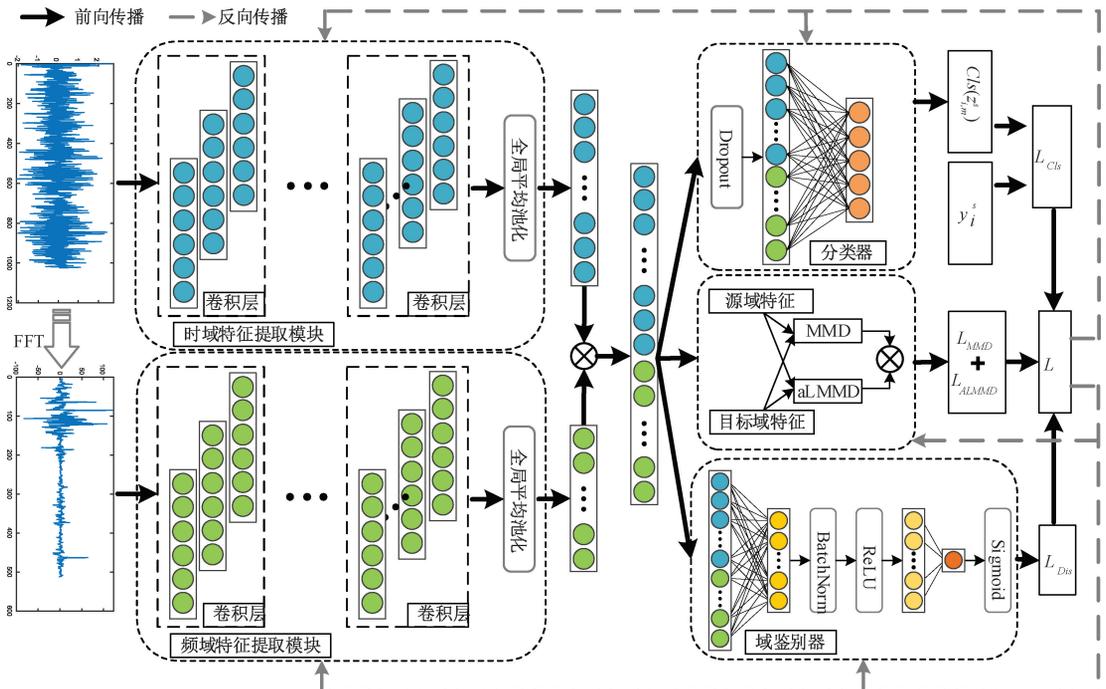


图 1 基于联合分布偏移差异的故障诊断模型

Fig. 1 A Cross-Domain Fault Diagnosis Method Based on Joint Distribution Offset Difference

### 1.1 时域与频域特征提取

时域振动信号可以包含丰富的故障特征而常常被用于智能故障诊断研究。为了滤除时域信号中的干扰成分以提升诊断精度,许多研究利用数据驱动方法从振动信号的频谱中挖掘故障信息并取得了成功。就众多研究的实验结论而言,时域信号和频域信号各有优势<sup>[1]</sup>。为了充分提取时域特征和频域特征,选择时域信号和频域信号共同作为诊断模型的输入数据。通常地,采用快速傅里叶变换(fast Furies transportation, FFT)处理时域信号以获得其频谱。

采用两条支路分别输入时域信号和频域信号,对两种信号进行最大最小值归一化处理。相应地采用两个独立的特征提取模块分别提取时域特征与频域特征。

CNN 的权值共享和局部感受野机制使得模型处理高维数据的效率大大提高,有效降低了模型参数量和计算资源消耗。采用 1-D 卷积神经网络(CNN)作为特征提取器,其具体结构如图 2 所示。

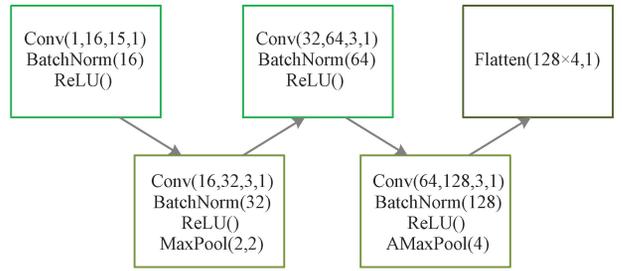


图 2 特征提取网络结构

Fig. 2 The structure of feature extraction network.

两个特征提取网络的结构完全相同,在前向通道上无任何交互,用以保证时域特征和频域特征的提取过程中不存在互相干扰。使用  $cnn_t(\cdot)$  与  $cnn_f(\cdot)$  表示时域特征与频域的特征提取器,将输入数据划分为:源域  $D_s$  的样本集  $\{x_i^s, y_i^s\}, i=1, 2, \dots, n_s-1, n_s$  与目标域  $D_t$  的样本集  $\{x_j^t\}, j=1, 2, \dots, n_t-1, n_t$ , 其中  $n_s$  与  $n_t$  分别表示源域与目标域的样本数。特征提取过程可表示如下:

$$\begin{cases} z_{i,t}^s = cnn_t(x_{i,t}^s) \\ z_{i,f}^s = cnn_f(x_{i,f}^s) \\ z_{j,t}^t = cnn_t(x_{j,t}^t) \\ z_{j,f}^t = cnn_f(x_{j,f}^t) \end{cases} \quad (1)$$

将两个特征提取模块输出的时域特征与频域特征,在通道维度上进行直接合并得到融合特征,即:

$$\begin{cases} z_{i,m}^s = z_{i,t}^s \oplus z_{i,f}^s \\ z_{i,m}^t = z_{i,t}^t \oplus z_{i,f}^t \end{cases} \quad (2)$$

从而最大程度地保留时域和频域故障信息。

### 1.2 特征分布对齐

#### 1) 自适应局部最大平均差异

现有的域自适应方法广泛应用最大平均差异来衡量两个域之间的距离,通过减小 MMD 从而实现源域特征和目标域特征的分布对齐,提升模型的域自适应能力。MMD 通常可以表示为:

$$L_{MMD} = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} \phi(z_{i,m}^s) - \frac{1}{n_t} \sum_{j=1}^{n_t} \phi(z_{j,m}^t) \right\|_H^2 \quad (3)$$

其中,  $H$  表示再生核希尔伯特空间(reproduced Kernel Hilbert space, RKHS),  $\phi(\cdot)$  为将特征映射到 RKHS 的非线性映射函数。令  $\kappa(\cdot)$  为再生核函数,与  $\phi(\cdot)$  存在关系:

$$\kappa(z_{i,m}^s, z_{j,m}^s) = \langle \phi(z_{i,m}^s), \phi(z_{j,m}^s) \rangle_H \quad (4)$$

可以得到 MMD 的一般计算式:

$$L_{MMD} = \frac{1}{n_s^2} \sum_i^{n_s} \sum_j^{n_s} \kappa(z_{i,m}^s, z_{j,m}^s) + \frac{1}{n_t^2} \sum_i^{n_t} \sum_j^{n_t} \kappa(z_{i,m}^t, z_{j,m}^t) - \frac{2}{n_s n_t} \sum_i^{n_s} \sum_j^{n_t} \kappa(z_{i,m}^s, z_{j,m}^t) \quad (5)$$

在具体实现过程中,通过计算源域数据与目标域数据的 L2 距离,再经由参数不同的若干个核函数处理,  $\kappa(\cdot)$  通常是高斯核函数或线性核函数,最终计算出源域和目标域特征之间的 MMD。然而,利用 MMD 计算样本之间的距离时,存在缺陷。由于目标域数据的类型未知,无法明确源域样本与目标域样本的类型是否一致,在计算域间距离时,将会受到类间差异的不利影响。

为了获得不同域中的相同类型样本之间的距离,将同一类别数据的分布进行对齐,局部最大平均差异(local MMD, LMMD)<sup>[23]</sup> 被提出,可表示如下:

$$L_{LMMD} = \frac{1}{C} \sum_{c=1}^C \left\| \sum_i^{n_s} w_i^{s,c} \phi(z_{i,m}^s) - \sum_j^{n_t} w_j^{t,c} \phi(z_{j,m}^t) \right\|_H^2 \quad (6)$$

式中:  $C$  表示类别数,第  $c$  类子域中,源域与目标域特征分布距离的权重  $w_i^{s,c}$  和  $w_j^{t,c}$  有:

$$\begin{cases} w_i^c = \frac{y_i^s}{n_s} & , \sum_i y_i^s = 1 \\ w_j^c = \frac{Cls(z_{j,m}^t)}{\sum_j Cls(z_{j,m}^t)} & , \sum_j Cls(z_{j,m}^t) = 1 \end{cases} \quad (7)$$

可以获得 LMMD 的计算式:

$$L_{LMMD} = \frac{1}{C} \sum_{c=1}^C \left[ \begin{aligned} & \frac{1}{n_s} \sum_i^{n_s} \sum_j^{n_s} w_i^{s,c} w_j^{s,c} \kappa(z_{i,m}^s, z_{j,m}^s) + \\ & \frac{1}{n_t} \sum_i^{n_t} \sum_j^{n_t} w_i^{t,c} w_j^{t,c} \kappa(z_{i,m}^t, z_{j,m}^t) - \\ & \frac{2}{n_s n_t} \sum_i^{n_s} \sum_j^{n_t} w_i^{s,c} w_j^{t,c} \kappa(z_{i,m}^s, z_{j,m}^t) \end{aligned} \right] \quad (8)$$

LMMD 相对 MMD 的改进之处在于利用分类器获取目标域样本的伪标签 (persuade label), 利用伪标签与源域样本的标签进行匹配。将伪标签与真实标签之积作为样本距离的系数, 增大标签一致的距离项的影响, 减小标签不一致的距离项的作用。尽管减小了类间差异对域间距离计算的影响, 但是 LMMD 在计算过程中应用的是伪标签, 即目标域样本的预测结果。在训练过程中, 当模型的对源域的分类性能还比较差时, 对目标域特征的分类能力也很差, 此时的伪标签与真实类型差距还很大, 从而导致 LMMD 不能很好地计算这一阶段的域间距离。此外, 相对于 MMD, LMMD 不仅消除了不同类型样本间的距离, 依据伪标签计算的子域分布距离权重也抑制了相同类型样本的类间距离的作用。

为了更好地计算域间距离, 对齐类别条件分布, 进一步抑制类间差异的不利影响, 提出了自适应局部最大平均差异 (adaptative local MMD, ALMMD), 利用自适应系数使模型更好地降低域间距离:

$$L_{ALMMD} = \sum_{c=1}^C \frac{\alpha^c}{C} \left[ \begin{aligned} & \frac{1}{n_s} \sum_i^{n_s} \sum_j^{n_s} w_i^{s,c} w_j^{s,c} \kappa(z_{i,m}^s, z_{j,m}^s) \\ & + \frac{1}{n_t} \sum_i^{n_t} \sum_j^{n_t} w_i^{t,c} w_j^{t,c} \kappa(z_{i,m}^t, z_{j,m}^t) \\ & - \frac{2}{n_s n_t} \sum_i^{n_s} \sum_j^{n_t} w_i^{s,c} w_j^{t,c} \kappa(z_{i,m}^s, z_{j,m}^t) \end{aligned} \right] \quad (9)$$

式中:  $\alpha^c, c = 1, 2, \dots, C - 1, C$  为自适应系数, 相比 LMMD, ALMMD 使用维度为  $1 \times C$  自适应系数, 宏观地调控每个类别样本的距离。 $\{\alpha^c\}$  随联合损失更新, 可以动态地、自适应地促进对域间距离的捕获。自适应系数的初始值被设置为  $1/C$ , 这意味着在训练早期, 分类器对目标域数据的估计也错误率较高之时, 依据伪标签计算的 LMMD 子项损失的影响较小。

## 2) 联合分布偏移差异

ALMMD 在分类器性能较差时, 也难以获得足够的成对的源域与目标域样本, 这将会导致损失太小, 阻碍了参数向预期的方向更新。为了有效地实现模型的域自适应, ALMMD 是不足的, 为了保留对全局分布偏移的度量, MMD 也被应用, 尤其是在训练早期, 对于特征分布对齐, MMD 将比 ALMMD 的贡献更大。

除了分布偏移损失, 域鉴别器  $Dis(\cdot)$  被用于对源域特征和目标域特征进行分类。由于可以借助域标签进行监督学习, 域鉴别器可以有效地促进特征提取网络提取域不变特征, 域鉴别器分类损失如下:

$$L_{Dis} = \frac{1}{n_s} \sum_{i=1}^{n_s} Dis(z_{i,m}^s) [\log(1 - Dis(z_{i,m}^s))] + \frac{1}{n_t} \sum_{j=1}^{n_t} Dis(z_{j,m}^t) [\log(1 - Dis(z_{j,m}^t))] \quad (10)$$

因此, 可以得到联合分布偏移差异损失:

$$L_{JDOD} = \mu L_{MMD} + \nu L_{ALMMD} + o L_{Dis} \quad (11)$$

其中,  $\mu, \nu$  和  $o$  为各部分损失的平衡系数。

## 3) 诊断模型参数更新

通过联合分布偏移差异, 可以将特征提取网络参数向降低特征分布差异和提取域不变特征的方向更新, 此外, 为了实现对样本的故障准确分类, 采用交叉熵损失计算源域标注样本的分类损失如下:

$$L_{Cls} = \frac{1}{n_s} \sum_{i=1}^{n_s} En(y_i^s, Cls(z_{i,m}^s)) = \frac{1}{n_s} \sum_{i=1}^{n_s} \sum_{c=1}^M Cls(z_{i,m}^s)_c \log(y_i^s) \quad (12)$$

令超参数  $\mu, \nu$  和  $o$  为平衡系数, 控制各部分损失的影响, 可得特征提取网络的总损失如下:

$$L = L_{Cls} + \mu L_{MMD} + \nu L_{ALMMD} + o L_{Dis} \quad (13)$$

本文采用随机梯度下降法 (stochastic gradient descent, SGD), 学习率为  $\eta$ , 更新特征提取模块参数  $\theta_{cnn}$ 、域鉴别器参数  $\theta_{Dis}$ 、ALMMD 自适应系数  $\theta_{almmd}$  和分类器参数  $\theta_{cls}$ :

$$\theta_{cnn} \leftarrow \theta_{cnn} - \eta \left( \frac{\partial L_{Cls}}{\partial \theta_{cnn}} + \mu \frac{\partial L_{MMD}}{\partial \theta_{cnn}} + \nu \frac{\partial L_{ALMMD}}{\partial \theta_{cnn}} + o \frac{\partial L_{Dis}}{\partial \theta_{cnn}} \right) \quad (14)$$

$$\theta_{cls} \leftarrow \theta_{cls} - \eta \frac{\partial L_{Cls}}{\partial \theta_{cls}} \quad (15)$$

$$\theta_{almmd} \leftarrow \theta_{almmd} - \eta \frac{\partial L_{ALMMD}}{\partial \theta_{almmd}} \quad (16)$$

$$\theta_{Dis} \leftarrow \theta_{Dis} - \eta \frac{\partial L_{Dis}}{\partial \theta_{Dis}} \quad (17)$$

## 2 实验

本节使用两个多工况的轴承故障诊断案例对所提出的跨域诊断模型进行性能评估。第 1 个是凯斯西部储备大学 (Case Western Reserve University, CWRU) 数据中心公开的电机轴承数据集。第 2 个是为重庆大学 (Chongqing University, CQU) 滚动轴承模拟退化平台上收集的数据集<sup>[2]</sup>。

### 2.1 实验对比方法设置

为了验证所提出方法的进步性,本文采用如下方法进行对比:

1) Source Only: 不施加任何域自适应策略,直接将源域监督训练的模型用于目标域,作为跨域故障诊断基准结果。

2) DAN<sup>[24]</sup>: 通过多核最大平均差异 (multi kernel maximum mean discrepancy, MKMMD) 实现源域与目标域特征的分布对齐进行跨域故障诊断。

3) DANN<sup>[25]</sup>: 利用特征提取器与域鉴别器的对抗训练 (即域对抗自适应), 实现对域不变特征的学习。

4) DSAN<sup>[23]</sup>: 通过局部最大平均差异 (LMMD) 将各个类别子域对齐来实现跨域故障诊断。

5) Deep Coral<sup>[26]</sup>: 使用线性变换方法将源域和目标域分布的二阶统计特征进行对齐。实现对无监督域的自适应。

6) BNM<sup>[27]</sup>: 采用 Fisher-norm 与特征矩阵的秩分别实现对无监督域预测结果的判别性约束和多样性约束。

7) DCTLN<sup>[11]</sup>: 应用域鉴别器与特征提取器的对抗学习和 MKMMD 分别学习域不变特征和对齐特征边缘分布。

8) LMMD Adv: 使用 LMMD 和域对抗自适应实现跨域故障诊断。此方法用于对比联合分布偏移差异以及将 LMMD 和域对抗自适应直接进行叠加。

9) JDOD: 本文所提出的基于联合分布偏移差异的跨域故障诊断方法。

### 2.2 CWRU 跨域故障诊断

#### 1) CWRU 数据集介绍

CWRU 数据中心发布的轴承数据集, 常常被用作检验旋转机械故障诊断方法, 是应用最多的基准数据集之

一。CWRU 数据集的实验平台如图 3 所示, 数据包含 4 种健康状态: 正常、滚动体故障、内圈故障和外圈故障。针对 3 种故障, 分别设计了 3 种故障尺寸: 0.007、0.014 和 0.021 英寸。同时, 设置了 4 种工作转速和载荷条件 (即 4 种工况): 1 797 rpm-0HP、1 972 rpm-1HP、1 750 rpm-2HP 和 1 730 rpm-3HP。本文以 3 种故障尺寸的 3 种故障状态与正常状态, 构建 10 种故障类型。为了进行跨域故障诊断实验, 将 4 种工况视作数据分布不同的 4 个域, 分别记为 0、1、2、3。为了方便同其他方法比较, 采用 1 024 为样本长度, 不重叠, 每种工况下获取 118×10 个样本, 按照 7:3 的比例划分训练集和测试集。

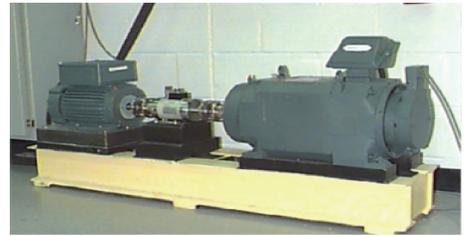


图 3 CWRU 轴承故障实验平台  
Fig. 3 CWRU bearing fault test rig

#### 2) CWRU 实验结果及分析

如第 2 节所述, 所有方法都应用一维卷积神经网络作为特征提取器, 分类器和域鉴别器结构如图 1 所示。

本文的实验设置 batch size 为 16, 随周期衰减的动态学习率机制, 衰减系数和周期分别为 0.9 和 50, 训练 500 个周期, 应用带动量的随机梯度下降 (stochastic gradient descend) 法更新网络参数, 动量参数为 0.9。

令 Tab 表示从源域 a 到目标域 b 的跨域故障诊断任务, 基于时域输入、频域输入和时频输入的诊断结果 (10 次重复实验的平均值), 诊断结果如表 1、2 和 3 所示。

表 1 CWRU 数据集上基于时域输入的诊断结果

Table 1 The diagnosis result based on time domain input of CWRU dataset

(%)

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	90.00	100.00	100.00	98.06	95.32	100.00	99.72	99.72	100.00
T02	88.89	99.72	100.00	99.72	93.61	100.00	100.00	99.72	99.72
T03	82.78	98.61	100.00	99.72	90.00	100.00	100.00	99.17	100.00
T10	89.72	99.72	99.72	98.06	94.72	100.00	100.00	95.00	99.44
T12	90.00	100.00	100.00	97.78	95.00	100.00	100.00	100.00	100.00
T13	88.06	99.72	100.00	96.39	93.33	98.89	100.00	97.50	100.00
T20	88.61	100.00	100.00	96.67	94.72	100.00	100.00	99.44	100.00
T21	88.06	99.72	99.72	97.78	92.50	99.72	100.00	98.33	99.17
T23	90.00	100.00	100.00	98.06	95.00	100.00	100.00	99.72	100.00
T30	86.39	90.56	99.17	87.78	81.94	99.72	99.72	94.17	99.17
T31	85.00	91.11	99.44	90.00	81.39	98.89	98.89	91.11	99.17
T32	87.78	99.72	100.00	99.72	93.89	100.00	100.00	95.56	100.00
平均值	87.94	98.24	99.84	96.65	91.79	99.81	99.86	97.45	99.72

表 2 CWRU 数据集上基于频域输入的诊断结果

Table 2 The diagnosis result based on frequency domain input of CWRU dataset

( % )

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	86.67	96.39	96.33	84.17	91.06	96.61	95.00	85.28	96.67
T02	85.83	95.28	95.50	88.06	89.39	96.33	97.50	83.61	97.50
T03	77.22	92.50	92.72	80.83	81.06	94.39	94.72	80.28	95.00
T10	85.00	92.22	94.94	82.78	87.17	94.94	95.28	88.33	95.28
T12	88.61	97.22	96.61	85.00	91.33	97.17	97.22	87.50	97.78
T13	82.50	93.06	94.94	80.28	84.94	96.06	96.11	81.17	96.67
T20	83.06	91.11	93.28	86.39	84.94	92.44	94.72	87.22	94.72
T21	86.39	93.06	93.83	86.94	88.56	95.50	94.17	88.06	94.44
T23	85.28	95.83	94.67	90.56	87.72	96.33	96.11	89.44	96.11
T30	78.61	89.72	92.72	85.56	82.44	92.17	93.61	83.89	93.06
T31	80.56	88.61	94.11	85.83	84.67	93.83	94.17	86.39	93.89
T32	88.06	95.28	96.61	90.00	91.61	96.89	95.56	89.17	96.94
平均值	83.98	93.36	94.69	85.53	87.07	95.22	95.35	85.86	95.67

表 3 CWRU 数据集上基于时频输入的诊断结果

Table 3 The diagnosis result based on time-frequency domain input of CWRU dataset

( % )

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	90.00	100.00	100.00	99.17	95.44	100.00	100.00	100.00	100.00
T02	89.72	100.00	100.00	99.72	95.00	100.00	100.00	99.72	100.00
T03	86.94	98.86	100.00	99.44	86.67	100.00	100.00	100.00	100.00
T10	90.00	100.00	100.00	97.50	96.33	100.00	100.00	99.17	100.00
T12	91.13	100.00	100.00	99.72	95.44	100.00	100.00	100.00	100.00
T13	89.89	99.72	100.00	99.17	93.61	99.44	100.00	99.72	100.00
T20	89.17	100.00	100.00	97.50	95.13	100.00	100.00	99.17	100.00
T21	89.17	100.00	100.00	97.50	95.44	100.00	100.00	98.86	99.72
T23	90.00	100.00	100.00	97.22	95.00	100.00	100.00	99.72	100.00
T30	84.44	95.72	99.72	98.09	96.11	99.72	99.72	98.33	100.00
T31	83.89	99.44	100.00	95.00	91.39	100.00	100.00	98.06	100.00
T32	90.00	100.00	100.00	100.00	94.17	100.00	100.00	100.00	100.00
平均值	88.70	99.48	99.98	98.34	94.14	99.93	99.98	99.40	99.98

根据以上 3 个表格的结果,通过横向对比,可以发现 DANN、BNM、DCTLN 以及本文提出的 JDOD 方法在 CWRU 轴承数据集上都能取得接近 100% 的平均诊断精度。通过纵向对比,在部分任务如 T03、T30 和 T31 等较远域的诊断任务中,各种方法的表现有明显下降。通过对比 3 个表格,可以发现时频输入网络相比单一域输入具有更高的平均诊断精度,体现了时域信息和频域信息互补对诊断精度具有提升作用。同时,所提出的 JDOD 的方法也取得了同比最高的平均诊断精度,证明了所提出跨域诊断模型的有效性。尽管诊断结果良好,在 CWRU 数据集上的实验却不能很好地验证所提出的方法的进步性,因此需要更具挑战性的诊断任务。

通过对 CWRU 实验结果的分析,可以发现工况差异越大,跨域诊断性能越差。从数据分布上看,工况差异越大也会造成更大程度的数据分布偏移,因而克服数据分布偏移的难度也就越大。因此设计了更具挑战性的基于

轴承模拟退化数据集的跨域故障诊断实验。

### 2.3 CQU 跨域故障诊断

#### 1) CQU 数据集介绍

用于实验的滚动轴承模拟退化平台如图 4 所示,由伺服电机、联轴器、轴承座、滚动轴承、传感器固定螺栓和控制器组成。振动数据集包含 5 种健康状态:正常、滚动体故障、内圈故障、外圈故障以及混合故障。将 5 中故障的标签设置为 1~5。安装在轴承座固定螺栓上的加速度计以 8 kHz 的采样频率采样 60 s。设置了 3 种转速以模拟 3 种工况:1 000、2 000 和 3 000 rpm,将 3 种工况分别记为:0,1,2。同样采用样本长度为 1 024,不重叠,每种工况获得 480×5 个样本,按照 7:3 的比例划分训练集和测试集。此数据集的实验设置与其他细节和 2.1 节完全相同。

#### 2) CQU 实验结果及分析

基于时域输入、频域输入和时频输入的诊断结果如

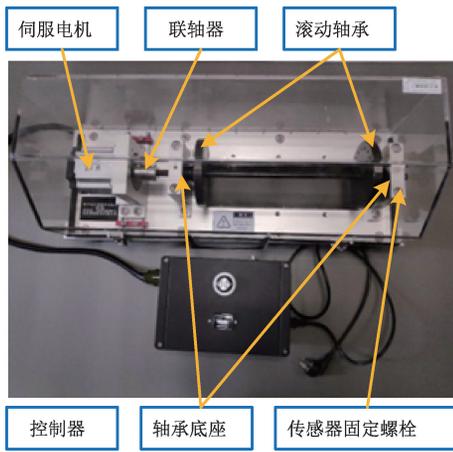


图 4 滚动轴承模拟退化平台

Fig. 4 Rolling bearing failure simulation test bench

表 4、5 和 6 所示。

在轴承模拟退化数据集的实验中,观察到与 CWRU 实验中类似的特点:(1)基于时频输入的诊断效果整体上要优于单一输入,再次表明时频输入相对单一域输入具有优势;(2)在时频输入的结果中,DANN、BNM 和所提出的方法(JDOD)依旧具有比其他方法更高的平均诊断精度。

DAN、DSAN 和 DCTLN 的在较远的跨域诊断任务(如 T20、T02)中表现却比较差,这反映出了仅依靠 MMD 注重边缘分布的不足。相对地,LMMD Adv 和 JDOD 方法在远域任务的诊断结果比较优秀。这表明兼顾边缘分布和条件分布对于较远域故障诊断任务具有提升作用。同时,通过对比 LMMD Adv 和 JDOD 方法在 3 种特征提取网络上的结果,可以验证自适应系数对 LMMD 的约束在源域和目标域特征的对齐中发挥了积极作用。

表 4 CQU 数据集上基于时域输入的诊断结果

Table 4 The diagnosis result based on time domain input of CQU dataset

(%)

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	97.36	99.44	99.86	99.86	99.17	100.00	99.86	100.00	99.86
T02	96.81	98.89	100.00	100.00	86.67	100.00	93.36	100.00	100.00
T10	92.36	98.61	99.86	98.33	90.56	98.61	100.00	99.44	100.00
T12	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
T20	56.67	77.25	77.50	77.50	68.47	97.36	78.75	90.50	99.03
T21	99.72	99.86	99.86	99.86	99.58	100.00	99.86	100.00	100.00
平均值	90.49	95.68	99.12	95.93	90.74	99.33	95.31	98.32	99.82

表 5 CQU 数据集上基于频域输入的诊断结果

Table 5 The diagnosis result based on frequency domain input of CQU dataset

(%)

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	90.06	93.19	97.50	90.56	97.36	96.72	91.81	78.75	96.81
T02	67.36	80.97	92.36	76.67	68.06	89.22	78.75	77.08	91.06
T10	83.47	87.64	94.44	86.67	85.14	93.47	93.61	87.36	92.50
T12	87.08	94.17	96.02	92.50	80.14	97.08	97.78	93.75	97.36
T20	76.53	70.42	91.00	73.75	72.08	90.00	85.14	81.81	92.92
T21	97.58	99.44	99.31	98.75	99.17	99.72	98.89	97.64	99.17
平均值	83.68	87.64	95.11	86.48	83.66	94.37	91.00	86.07	94.97

表 6 CQU 数据集上基于时频输入的诊断结果

Table 6 The diagnosis result based on time-frequency domain input of CQU dataset

(%)

任务	Source Only	DAN	DANN	DSAN	Deep Coral	BNM	DCTLN	LMMD Adv	JDOD
T01	95.83	99.72	100.00	99.58	95.97	100.00	100.00	99.86	100.00
T02	84.86	99.44	100.00	100.00	89.17	100.00	94.03	99.86	99.86
T10	87.08	98.75	99.86	98.89	89.03	98.89	100.00	98.75	99.86
T12	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
T20	70.14	78.89	96.31	78.19	78.33	97.08	80.69	98.89	99.86
T21	100.00	100.00	100.00	99.72	100.00	100.00	100.00	99.86	100.00
平均值	89.65	96.13	99.36	96.06	92.08	99.33	95.79	99.54	99.93

对于各个方法表现都很好的任务,本文不给予过多关注。为了更好地评估模型性能,本文选择各种方法的诊断结果差异较大的 T20 任务进行消融结果分析。选择 Source Only 方法、JDOD 方法以及与 JDOD 方法相关程度较高的方法: DAN (MMD)、DANN (域对抗自适应)、DSAN (LMMD)、DCTLN (MMD+域对抗自适应),基于时频输入,在 T20 任务中的诊断结果进行分析。

图 5 展示了几种方法的诊断结果的混淆矩阵。观察到 Source Only 和 DSAN 方法对于故障 1 和 4 产生了严重

误判,仅仅依靠 LMMD 是不够的;DCTLN 和 DAN 一定程度上改善了对于故障 1 和 4 的误判问题,却不能达到较高的诊断精度;DANN 基于域对抗自适应策略,取得了比较均匀且较好的结果,但仍然有不小的上升空间;对比 DANN 和 DCTLN 可以发现仅仅依靠 MMD 对齐边缘分布造成了负面影响;JDOD 方法在每个故障类别的诊断上取都得了最佳的结果,证明了联合分布偏移差异在较远的跨域故障诊断任务中具有明显优势。

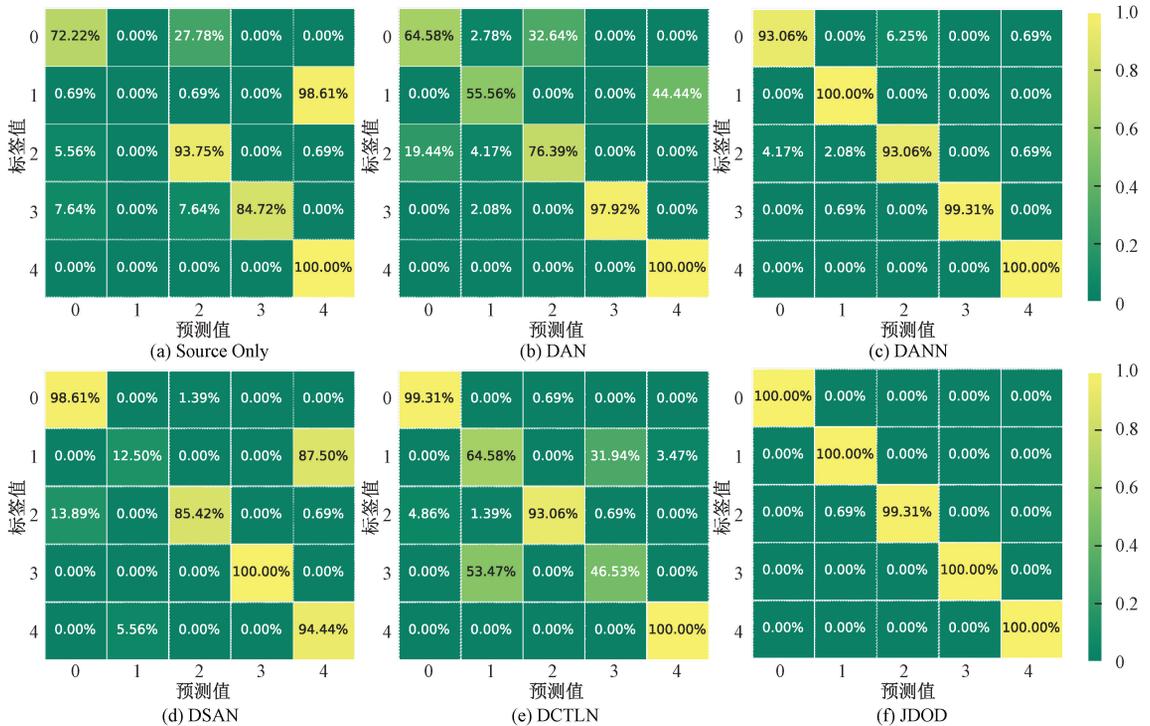


图 5 不同方法在 T20 任务中诊断结果的混淆矩阵

Fig. 5 Confusion matrixes of diagnostic results of different methods in T20 task

为了更直观地观察利用联合分布偏移差异指导更新的特征提取网络的性能,使用 tsne 算法对时域和频域的融合特征进行降维,并将其进行可视化,如图 6 所示。观察到 Source Only 方法和 DSAN 方法的特征分布中,故障 1 和 4 混叠的较为严重,这正与混淆矩阵的结果相对应;对比 DANN 和 JDOD 方法,DANN 方法中故障 0 和 2 的距离较近,特征可分性更差,体现了利用 ALMMD 实现条件分布对齐的优势;JDOD 方法提取的特征分布的特征聚集程度和可分性明显优于其他方法。

### 3 结论

本文提出了一种基于联合分布偏移差异的跨域滚动轴承故障诊断方法。使用两个独立且结构一致的 CNN 特征提取网络,分别从时域信号和频谱中提取特征并进

行融合。提出了由全局最大平均差异、自适应局部最大平均差异和域鉴别器分类损失构成的联合分布偏移差异,与源域数据的监督分类损失一并指导特征提取器的参数更新。在两个多工况轴承数据集上开展了跨域故障诊断实验,所提出的方法在整体上取得了优于其他域自适应方法的结果。在工况差异较大的实验中,对于所提出的方法,基于时频输入相比基于时域输入和基于频域输入,平均诊断精度分别提升了 0.11% 和 4.96%。相比无域自适应策略的方法以及单一的最大平均差异和域对抗自适应方法,在基于时频输入的实验中分别提升了 10.28%、3.80% 和 0.57%。实验结果证明了时频特征提取和联合分布偏移差异,能够有效提升模型的域自适应能力和跨域故障诊断精度。

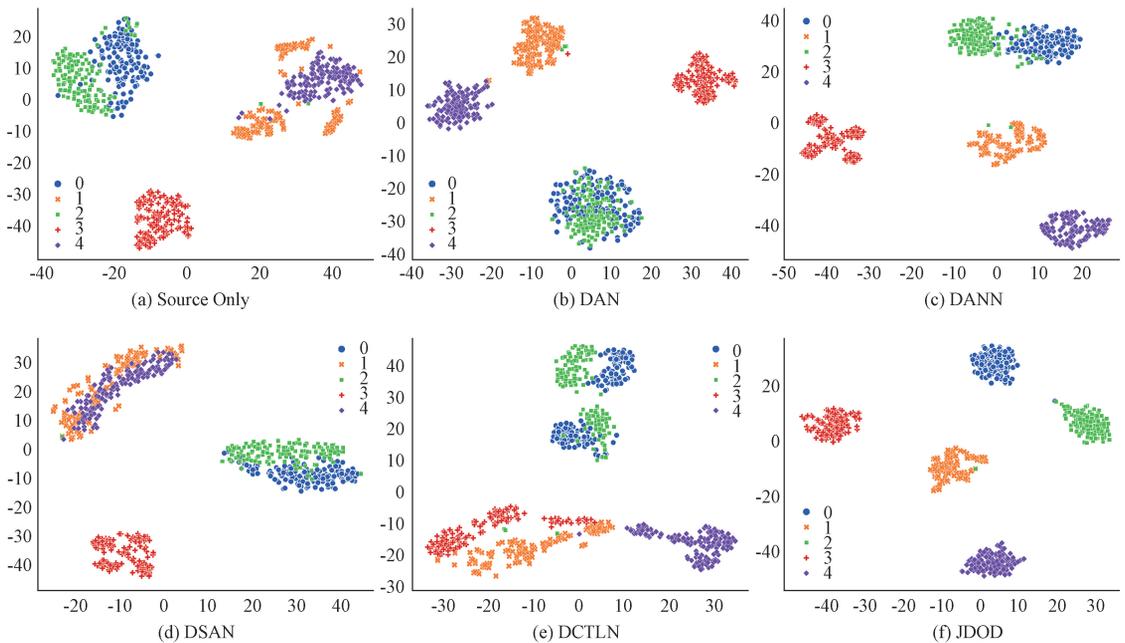


图 6 不同方法在 T20 诊断任务中的融合特征分布

Fig. 6 Fusion feature distribution of different methods in T20 diagnostic task

## 参考文献

- [ 1 ] LEI Y, YANG B, JIANG X, et al. Applications of machine learning to machine fault diagnosis; A review and roadmap [ J ]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [ 2 ] AN Y, ZHANG K, LIU Q, et al. Rolling bearing fault diagnosis method base on periodic sparse attention and LSTM [ J ]. IEEE Sensors Journal, 2022; 1-10.
- [ 3 ] 崔鹏宇,王泽勇,邱春蓉,等.基于 IBA 优化 BP 神经网络的滚动轴承故障诊断方法 [ J ]. 电子测量技术, 2019,42(12):33-36.
- CUI P Y, WANG Z Y, QIU CH R, et al, Fault diagnosis of rolling bearing s based on IBA optimized BP neural network [ J ]. Electronic Measurement Technology,2019,42(12):33-36.
- [ 4 ] 宫文峰,陈辉,张美玲,等.基于深度学习的电机轴承微小故障智能诊断方法 [ J ]. 仪器仪表学报,2020,41(1):195-205.
- GONG W F, CHEN H, ZHANG M L, et al, Intelligent diagnosis method for incipient fault of motor bearing based on deep learning [ J ]. Chinese Journal of Scientific Instrument,2020,41(1):195-205.
- [ 5 ] 谢佳琪,尤伟,沈长青,等.基于改进卷积深度置信网络的轴承故障诊断研究 [ J ]. 电子测量与仪器学报, 2020,34(2):36-43.
- XIE J Q, YOU W, SHEN CH Q, et al, Bearing fault diagnosis based on improved convolution deep belief network [ J ]. Journal of Electronic Measurement and Instrumentation,2020,34(2):36-43.
- [ 6 ] GAO S, PEI Z, ZHANG Y, et al. Bearing fault diagnosis based on adaptive convolutional neural network with Nesterov momentum [ J ]. IEEE Sensors Journal, 2021, 21(7): 9268-9276.
- [ 7 ] 范勇,王鹏,张宇超.基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究 [ J ]. 国外电子测量技术,2020,39(8):5-10.
- FAN Y, WANG P, ZHANG N CH, Research on automaton driving mechanism fault diagnosis based on improved EMD and SOM neural network [ J ]. Foreign Electronic Measurement Technology,2020,39(8):5-10.
- [ 8 ] CHEN Z, GRYLLIAS K, LI W. Intelligent fault diagnosis for rotary machinery using transferable convolutional neural network [ J ]. IEEE Transactions on Industrial Informatics, 2019, 16(1): 339-349.
- [ 9 ] SHAO H, XIA M, HAN G, et al. Intelligent fault diagnosis of rotor-bearing system under varying working conditions with modified transfer convolutional neural network and thermal images [ J ]. IEEE Transactions on Industrial Informatics, 2020, 17(5): 3488-3496.
- [ 10 ] 廖玉波,俞啸,李伟生,等.基于深度置信网络的旋转机械迁移故障诊断 [ J ]. 机电工程, 2022, 39(2): 193-201.
- LIAO Y B, YU X, LI W SH, et al, Transfer fault diagnosis for rotating machinery based on deep belief

- network [J]. *Journal of Mechanical & Electrical Engineering*, 2022, 39(2):193-201.
- [11] GUO L, LEI Y, XING S, et al. Deep convolutional transfer learning network: A new method for intelligent fault diagnosis of machines with unlabeled data [J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(9): 7316-7325.
- [12] ZHANG Y, REN Z, ZHOU S, et al. Adversarial domain adaptation with classifier alignment for cross-domain intelligent fault diagnosis of multiple source domains[J]. *Measurement Science and Technology*, 2020, 32(3): 035102.
- [13] LI X, ZHANG W. Deep learning-based partial domain adaptation method on intelligent machinery fault diagnostics [J]. *IEEE Transactions on Industrial Electronics*, 2020, 68(5): 4351-4361.
- [14] JIN T, YAN C, CHEN C, et al. New domain adaptation method in shallow and deep layers of the CNN for bearing fault diagnosis under different working conditions [J]. *The International Journal of Advanced Manufacturing Technology*, 2021: 1-12.
- [15] JIAO J, ZHAO M, LIN J. Unsupervised adversarial adaptation network for intelligent fault diagnosis [J]. *IEEE Transactions on Industrial Electronics*, 2019, 67(11): 9904-9913.
- [16] LI Y, REN Y, ZHENG H, et al. A novel cross-domain intelligent fault diagnosis method based on entropy features and transfer learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-14.
- [17] 胡若晖, 张敏, 许文鑫. 基于 DCGAN 和 DANN 网络的滚动轴承跨域故障诊断[J]. *振动与冲击*, 2022, 41(6): 21-29.
- HU R H, ZHANG M, XU W X. Cross-domain fault diagnosis of rolling element bearings using DCGAN and DANN [J], *Journal of Vibration and Shock*, 2022, 41(6):21-29.
- [18] ZHANG Y, YU K, REN Z, et al. Joint domain alignment and class alignment method for cross-domain fault diagnosis of rotating machinery [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-12.
- [19] LI X, ZHANG W, XU N X, et al. Deep learning-based machinery fault diagnostics with domain adaptation across sensors at different places [J]. *IEEE Transactions on Industrial Electronics*, 2019, 67(8): 6785-6794.
- [20] 夏懿, 徐文学. 一种用于跨域轴承故障诊断的深度自适应网络[J]. *振动与冲击*, 2022, 41(3):45-53.
- XIA Y, XU W X, A deep adaptive network for cross-domain bearing fault diagnosis [J]. *Journal of Vibration and Shock*, 2022, 41(3):45-53.
- [21] YAN X, LIU Y, JIA M. Multiscale cascading deep belief network for fault identification of rotating machinery under various working conditions [J]. *Knowledge-Based Systems*, 2020, 193: 105484.
- [22] JIANG G, HE H, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(4): 3196-3207.
- [23] ZHU Y, ZHUANG F, WANG J, et al. Deep subdomain adaptation network for image classification [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, 32(4): 1713-1722.
- [24] LONG M, CAO Y, WANG J, et al. Learning transferable features with deep adaptation networks[C]. *International Conference on Machine Learning*. PMLR, 2015: 97-105.
- [25] GANIN Y, LEMPITSKY V. Unsupervised domain adaptation by backpropagation [C]. *International Conference on Machine Learning*. PMLR, 2015: 1180-1189.
- [26] SUN B, SAENKO K. Deep coral: Correlation alignment for deep domain adaptation[C]. *European Conference on Computer Vision*. Springer, Cham, 2016: 443-450.
- [27] CUI S, WANG S, ZHUO J, et al. Towards discriminability and diversity: Batch nuclear-norm maximization under label insufficient situations [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 3941-3950.

## 作者简介



雷杨博, 2020 年于重庆邮电大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为深度学习和智能故障诊断。E-mail: yangbl1998@126.com

Lei Yangbo received his B. Sc. degree from Chongqing University of Posts and Telecommunications in 2020. Now he is a M. Sc. candidate in Chongqing University of Posts and Telecommunications. His main research interests include deep learning and intelligent fault diagnosis.



朱智勤 (通信作者), 2010 年于重庆大学获得学士学位, 2016 年获得重庆大学博士学位。现为重庆邮电大学副教授。主要研究方向为图像处理、机器学习与智能控制。

E-mail: zhuzq@cqupt.edu.cn

Zhu Zhiqin (Corresponding author) received his B. Sc.

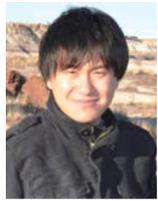
degree from Chongqing University in 2010, Ph. D. degree from Chongqing University in 2016, respectively. Now he is an associate professor in Chongqing University of Posts and Telecommunications. His main research interests include image processing, machine learning and intelligent control.



**柴毅**, 1982 年获得国防科学技术大学学士学位, 2001 年获得重庆大学博士学位。现为重庆大学教授。主要研究方向为信息处理、智能系统理论及其应用等。

E-mail: chaiyi@cqu.edu.cn

**Chai Yi** received his B. Sc. degree from National University of Defense Technology in 1982, Ph. D. degree from Chongqing University in 2001, respectively. Now he is a professor in Chongqing University. His main research interests include information processing, intelligent system theory and its applications and so on.



**齐观秋**, 2008 年于南京大学获得学士学位, 2016 年于亚利桑那州立大学获得博士学位, 主要研究方向为软件故障诊断、软件测试、机器学习等。

E-mail: qig@buffalostate.edu

**Qi Guanqiu** received his B. Sc. degree from Nanjing University in 2008 and Ph. D. from Arizona State

University in 2016. His main research interests include software troubleshooting, software testing, machine learning, etc.



**安翼尧**, 2017 年于重庆大学获得学士学位, 现为重庆大学博士研究生, 主要研究方向为智能故障诊断算法、迁移学习与深度学习。

E-mail: anyiyao@cqu.edu.cn

**An Yiyao** received his B. Sc. degree from Chongqing University of Posts and Telecommunications in 2017. Now he is a Ph. D. student in Chongqing University of Posts and Telecommunications. His main research interests include intelligent fault diagnosis algorithms, transfer learning and deep learning.



**徐鹏**, 2020 年于重庆邮电大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为深度学习理论与应用研究。

E-mail: senmutli123@gmail.com

**Xu Peng** received his B. Sc. degree from Chongqing University of Posts and Telecommunications in 2020. Now he is a M. Sc. candidate in Chongqing University of Posts and Telecommunications. His main research interests include deep learning theory and application research.