

## 基于域对抗统计特性增强的跨域故障诊断方法

朱俞豪, 张泓钊, 张永

引用本文

朱俞豪, 张泓钊, 张永. 基于域对抗统计特性增强的跨域故障诊断方法[J]. 计算机科学, 2024, 51(6A): 230700196-6.

ZHU Yuhao, ZHANG Songzhao, ZHANG Yong. [Domain-adversarial Statistical Enhancement for Cross-domain Fault Diagnosis](#) [J]. Computer Science, 2024, 51(6A): 230700196-6.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

### [基于SAMNV3的滚动轴承智能故障诊断方法](#)

Intelligent Fault Diagnosis Method for Rolling Bearing Based on SAMNV3

计算机科学, 2024, 51(6A): 230700167-6. <https://doi.org/10.11896/jsjcx.230700167>

### [基于知识图残差注意力网络的推荐方法](#)

Recommendation Method Based on Knowledge Graph Residual Attention Networks

计算机科学, 2023, 50(11A): 220900180-7. <https://doi.org/10.11896/jsjcx.220900180>

### [基于核鲁棒流形非负矩阵分解和融合特征的柴油机故障诊断](#)

Diesel Engine Fault Diagnosis Based on Kernel Robust Manifold Nonnegative Matrix Factorization and Fusion Features

计算机科学, 2023, 50(6A): 220400128-8. <https://doi.org/10.11896/jsjcx.220400128>

### [基于独立注意力机制的图像检索算法](#)

Image Retrieval Based on Independent Attention Mechanism

计算机科学, 2023, 50(6A): 220300092-6. <https://doi.org/10.11896/jsjcx.220300092>

### [基于迁移学习的跨对象手语手势识别方法](#)

Transfer Learning Based Cross-object Sign Language Gesture Recognition Method

计算机科学, 2023, 50(6A): 220300232-5. <https://doi.org/10.11896/jsjcx.220300232>

# 基于域对抗统计特性增强的跨域故障诊断方法

朱俞豪<sup>1</sup> 张淞钊<sup>1</sup> 张永<sup>1,2</sup>

1 湖州师范学院信息工程学院 浙江 湖州 313000

2 辽宁师范大学计算机与信息技术学院 辽宁 大连 116081

(zyhff20160919@163.com)

**摘要** 故障诊断对于保障大型机械设备安全稳定运行具有十分重要的意义,但获得的数据存在严重标签缺失或缺少的问题,且不同工况下的数据特征分布显著不同。传统机器学习或微调的方法存在特征提取模式单一、视角固定的局限性,使得同类不同域的特征难以对齐。针对以上问题,文中提出了一种基于域对抗统计特性增强的跨域故障诊断方法 DASEM(Domain-Adversarial Statistical Enhancement Model)。该方法采用直推式深度迁移学习技术,在域对抗框架下增强全局统计特性的表示,并与局部结构模式融合,构建双路特征提取器。同时,利用域标签和数据结构之间的平衡关系来描述域对抗的表现形式,并通过类标签输出故障诊断结果。在西储大学轴承数据集和江南大学轴承数据集上的实验结果显示,DASEM 在各个跨域任务上的平均精度分别达到了 94.90% 和 93.15%,证明了该方法的有效性。

**关键词:** 故障诊断; 特征分布对齐; 域对抗; 全局统计特性

**中图分类号** TP181

## Domain-adversarial Statistical Enhancement for Cross-domain Fault Diagnosis

ZHU Yuhao<sup>1</sup>, ZHANG Songzhao<sup>1</sup> and ZHANG Yong<sup>1,2</sup>

1 School of Information Engineering, Huzhou University, Huzhou, Zhejiang 313000, China

2 School of Computer & Information Technology, Liaoning Normal University, Dalian, Liaoning 116081, China

**Abstract** Fault diagnosis is of great importance in ensuring the safe and stable operation of large-scale mechanical equipment. However, the obtained data often suffer from severe label shortages or lack of labels, and the data distribution varies significantly at different operating conditions. Traditional machine learning or fine-tuning methods have limitations in feature extraction, with a single pattern and fixed perspective, making it difficult to align features of the same class but different domains. To address these issues, this paper proposes a domain-adversarial statistical enhancement-based cross-domain fault diagnosis method called DASEM. This method utilizes direct transfer deep learning techniques to enhance the representation of global statistical characteristics within the framework of domain adversarial learning. It also integrates these characteristics with local structural patterns by constructing a dual-path feature extractor. The balance between domain labels and data structures is utilized to describe the manifestation of domain adversarial learning, and the fault diagnosis results are outputted based on class labels. Experimental results on the bearing datasets from Western Reserve University and Jiangnan University demonstrate the effectiveness of DASEM, achieving an average accuracy of 94.90% and 93.15%, respectively, for various cross-domain tasks.

**Keywords** Fault diagnosis, Feature distribution alignment, Domain adversarial, Global statistical characteristics

## 1 引言

故障诊断通过对机械整体或局部关键部位信号的监测,来判断机械某个部位的健康状态。通过对故障位置的定位和故障类型的预测,可以及时对其进行修复,从而避免该部位损坏程度的加剧或出现二次损坏。滚动轴承是一种重要的精密机械元件,但随着使用率和使用时间的增加,滚动轴承极易出现缺口、裂纹等类型的损伤,严重时会导致机械整体瘫痪以及生产停滞。因此对滚动轴承进行实时监测和故障诊断十分必要。

基于传统机器学习的故障诊断方法从时域、频域和时频

域出发,采用傅里叶变换<sup>[1]</sup>、经典频谱分析<sup>[2]</sup>、短时傅里叶变换<sup>[3]</sup>、Hilbert-Huang 变换<sup>[4]</sup>、小波变换<sup>[5]</sup>、Wigner-Ville 分布<sup>[6]</sup>等技术来提取故障相关特征。并将提取到的特征输入支持向量机、逻辑回归等分类器中进行故障分类。尽管这类方法存在实用性强、灵敏度高、运算量小、建模难度低等优点,但它在早期潜在的故障诊断任务中仍有不足,比如,对于扰的排除性差;故障分类的结果过度依赖特征提取的效果;难以应用于跨域任务。现有的大多数方法只适用于特定的工况,而受运行速度、负载等物理环境因素的影响,不同环境下采集的振动信号会存在域协变量漂移问题,即特征空间分布前后差异较大<sup>[7]</sup>的情况。

基金项目:辽宁省教育厅科学研究经费项目(LJKZ0965);湖州科技计划项目(2022GZ08,2023ZD2004)

This work was supported by the Scientific Research Foundation of the Education Department of Liaoning Province(LJKZ0965) and Huzhou Science and Technology Plan Project(2022GZ08,2023ZD2004).

通信作者:张永(zhyong@zjhu.edu.cn)

深度学习可在高层次上对数据重新进行非线性表示、计算、筛选、合并和继承等操作,并通过多级不同功能的层次结构对数据进行分类或预测。本文提出了一种基于域对抗统计特性增强的跨域故障诊断方法,在域对抗框架下增强了全局统计特性的表示,并与局部结构模式相融合,从而构建了双路径特征提取器。该方法按照端到端的设计理念,从各个域的原始振动信号中自动提取特征并粗略判别故障类型,然后在与域鉴别器的对抗中学习一个深度神经网络模型。本文的主要贡献有以下几点:1)使用统计特性提取振动信号特征:将振动信号的统计特性用于故障诊断,并对这些特征进行量化、计数和增强等加工;2)引入门组件的组合特征提取器:在特征提取器中引入了输入门、输出门和临时记忆单元的组合,通过遗忘冗余特征,减轻下游图卷积网络的计算负担;3)多层次使用图结构:通过采用图结构建模,考虑各个域和数据之间的关系,使得有直接或间接联系的数据能够更好地表达;4)基于最大均值差异(Maximum Mean Discrepancy, MMD)<sup>[8]</sup>的域对抗解释:在考虑类标签和域标签的基础上,同时对数据结构<sup>[9]</sup>进行建模,利用 MMD 这一可直接测量的度量方法辅助解释对抗过程。

## 2 相关工作

基于数据驱动的无监督深度学习的跨域故障诊断方法主要分为微调(Fine-tune)和域适应,其核心思想是利用深度迁移技术,使得易获取故障的源域数据与标记代价高昂的目标域数据映射在相同的特征分布空间内,即通过特征提取令二者域对齐<sup>[10]</sup>。

在跨域故障诊断领域中,微调是最常用的迁移学习方法。其原理是冻结已完成预训练模型中部分层的参数,其余层的参数由少量标记数据调整。Zhang 等<sup>[11]</sup>使用源域数据预训练特征提取器,在反向传播过程中微调特征提取器的非约束自适应层参数,在齿轮箱数据集 20 个域迁移任务上的平均诊断准确率达到 82.62%。Shao 等<sup>[12]</sup>和 Cao 等<sup>[13]</sup>提出的方法较未使用微调的模型分别实现了 6% 和 21% 的性能提升。然

而此类方法有着明显的局限性,即参与微调的目标域数据未必同完成预训练的源域数据具备相同的特征分布空间。Jiang 等<sup>[14]</sup>利用振动信号表现的多尺度特性,在保留原始信号的特征表示的同时,又在多个时间尺度上(划分不同的粗粒度大小)对其进行平滑和降采样,模糊了不同工况下的特征空间结构上的差距。但该方法并未定义一种可测量的度量来描述域对齐的变化。

域对抗是直推式迁移学习的一个重要分支,其目标是通过对抗的方式令特征提取器生成能够同时适应两个域的特征。通常认为,域对抗是特征提取器和域鉴别器之间的最小值博弈。域鉴别器的任务是判断被诊断的振动信号属于源域还是目标域,因此它会将域鉴别的损失优化至最小,同时也会导致源域和目标域在特征空间上的距离增大。而特征提取器的任务是为故障分类器提供特征,以准确判断所有数据的故障类型,这就要求源域和目标域的特征分布相互对齐,即将源域和目标域之间的距离优化至最小,但这会导致域鉴别器的鉴别效果不佳。总的来说,域对抗故障诊断通过特征提取器和域鉴别器之间的对抗训练来促进源域和目标域之间的特征对齐。通过平衡特征提取和域鉴别的训练过程,可以获得在目标域上有效的故障诊断模型。本文使用 MMD 来描述源域与目标域之间的度量。

## 3 基于域对抗统计特性增强的跨域故障诊断

本章将详细介绍所提出的域对抗统计特性增强模型(Domain-Adversarial Statistical Enhancement Model, DASEM)。首先,3.1 节详细描述 DASEM 的整体结构,然后 3.2 节着重阐述量化和计数算子-增强模型(Quantization and Counting Operator & Enhance Module, QCO-EM)<sup>[15]</sup>。在可变工况下,由于所设计的智能故障诊断模型的整体结构为特征提取器和域鉴别器呈对抗关系的网络,因此 3.3 节给出了几者的损失,并给出了总的损失函数。

### 3.1 模型的整体结构

DASEM 的整体结构如图 1 所示。

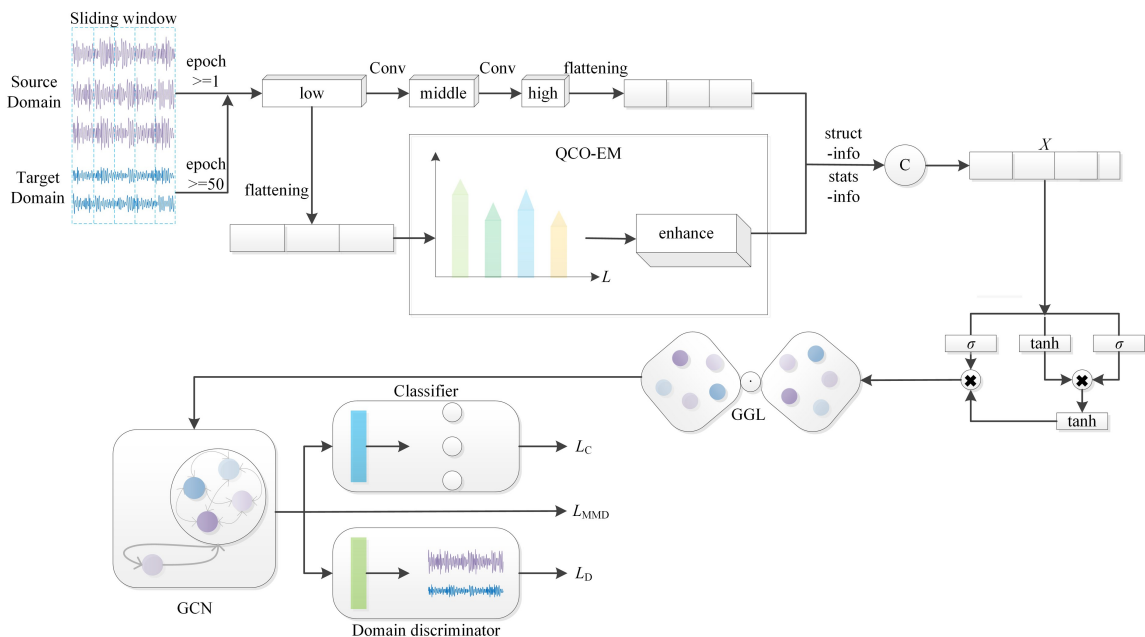


图 1 DASEM 的整体结构

Fig. 1 Overall structure of DASEM

DASEM 可分为两部分:主干网络,主要提取局部结构模式,如边界、平滑度、粗糙度等;分支网络,主要从低层信息中提取容易被忽略的全局统计特性。主干网络和分支网络的位置为并联关系,二者构成双路径特征提取器。分支网络所需的传入数据并非用于故障诊断的原始振动信号,而是源自主干网络中的低层信息。低层信息为经过单次卷积神经网络(Convolutional Neural Network, CNN)提取的原始振动信号的特征表达。低层信息在分支网络中经量化和计数算子-增强模型 QCO-EM 传出的信息便为全局统计信息。在结构模式特征流经子网络 CNN 后,将其与统计信息合并为中间特征  $X$ ,继而向下一个子网络传递。逻辑门的组合对中间特征  $X$  进行部分遗忘,即将部分维度的特征予以舍弃。被舍弃特征后的数据传入至图生成层网络(Graph Generation Layer network, GGL),生成邻接矩阵,使得图卷积网络(Graph Convolutional Network, GCN)开始工作。经 GCN 处理后的数据同时传入故障分类器和域鉴别器,在全连接层(Fully Connected layer, FC)的作用下分别生成预测的故障标签和域标签。

### 3.2 量化和计数算子-增强模型(QCO-EM)

在 CNN 等深度神经网络中,即使是最小的深层高级特征单元,也具有广泛的感受野,容易学习到边界等局部特征。然而,这不可避免地会导致一些关键的低层统计信息被忽略,从而导致故障诊断结果粗糙或不准确。为了解决这个问题,本文引入量化和计数算子(QCO)特征编码方法,以充分利用低层的全局属性,从而提高故障诊断结果的准确性和精细程度。

QCO 是一种稳定的且自适应的特征编码方法,能够以统计形式有效地描述低层信息中的全局属性。QCO 分为量化、计数与平均特征编码两个阶段。在量化阶段,将低层特征映射到一个离散的特征空间,以捕获重要的特征值;在计数与平均特征编码阶段,对离散特征进行统计,得到每个特征值的频数,然后通过对特征值和频数进行加权平均,得到具有全局属性的特征编码。经过 QCO 编码后,可以使用图传播方法来进一步丰富量化后的信息,以增强低层特征的细节。具体流程如图 2 所示。

1)量化。即由输入特征图  $I$  构造量化编码图  $Q$  的过程。 $I$  上每个空间位置定义为  $I_{i,j}$  ( $i \in [1, H], j \in [1, W]$ ),这里  $H$  和  $W$  分别表示特征图的高度和宽度。首先,将输入特征图进行全域平均池化(输入特征图的通道数由源起的 CNN 低层卷积核数目决定),得到  $C$  个全局平均特征  $g$ 。在对应的  $I$  上,计算每个  $I_{i,j}$  与  $g$  的余弦相似度,拉直得到  $I'$ ,  $I'$  上每个空间位置定义为  $I'_i$  ( $i \in [1, HW]$ )。构造  $N$  个量化级别,由此进行量化,第  $k$  ( $k \in [1, N]$ )级由式(1)计算:

$$L_k = \frac{\max(I') - \min(I')}{N} \times k + \min(I') \quad (1)$$

针对每个量化级别,得到可以反映  $I'$  量化水平的量化编码图  $Q$ ,如式(2)所示:

$$Q_{i,k} = \begin{cases} 1 - |L_k - I'_i|, & |L_k - I'_i| \leq \frac{0.5}{N} \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

2)计数与平均特征编码。即生成统计特征  $S$  的过程。将  $N$  个量化级别上的  $Q_i$  均值化后与  $L$  合并,再与上采样至  $N$  个的  $g$  合并,经多层感知机(MultiLayer Perceptron, MLP)确定统计特征  $S$ ,其结构为  $S \in R^{N \times C_1}$ 。

3)增强。即如何进行图传播,并最终得到输出特征  $O$  的过程。QCO 是对主干网络中低层信息进行特征编码的一种方法。但低层特征由于经历的提取层数太少,往往存在特征质量较低、对比度差等缺点。基于这些限制条件构造的统计特征  $S$ ,仍需增强其细节,以便下游子网络获得更全面的属性。这是一种模仿直方图量化过程的方法。在计算机视觉中,用以量化的直方图的横轴和纵轴分别表示每个灰度及其计数值,而在这里,横轴代表具体灰度的向量  $G$ ,纵轴代表  $G$  中每个元素在图中统计出的数量的向量  $F$ 。 $G$  由  $N$  维构成,即被视作有  $N$  个不同的级别。希望通过  $F$  重建  $G$ ,得到  $G'$ ,计算式如式(3)所示:

$$G'_k = \frac{(N-1) \times \sum_{i=0}^k F_i}{\sum_{i=0}^k F_i} \quad (3)$$

其中,  $k \in [1, N]$ 。

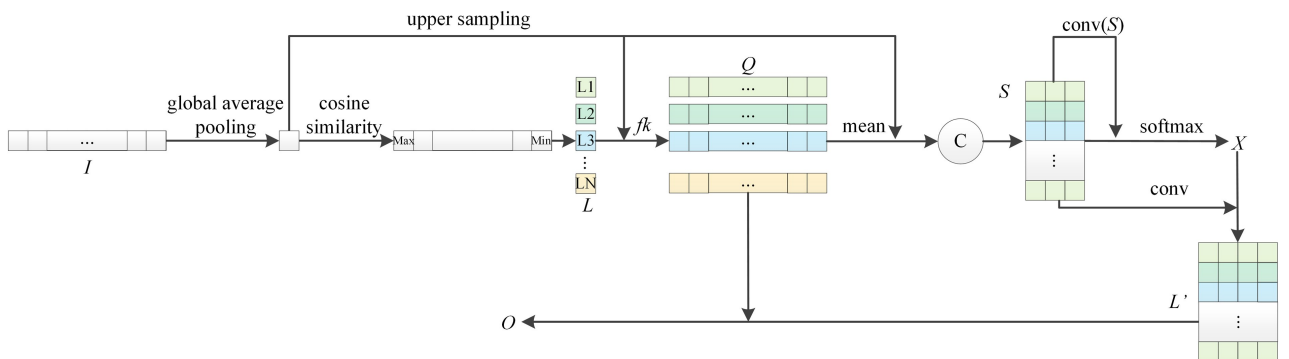


图 2 单通道下的 QCO-EM 结构

Fig. 2 QCO-EM structure under single channel

统计特征  $S$  可类比于直方图,需要将其重建为  $L'$ 。由  $I$  到  $L$  和  $Q$  的过程,  $g \cdot L$  和  $Q$  到  $S$  的过程,以及  $S$  到  $L'$  的过程可知,新层级是由原始层级的统计信息得到,而新层级对原始层级进行感知,需要使用图传播。其计算式如式(4)所示:

$$L' = \text{conv1}(S) \cdot \text{Softmax}(\text{conv2}(S^T)) \cdot \text{conv3}(S) \quad (4)$$

其中,  $\cdot$  为矩阵相乘符号,  $\text{conv1}$ ,  $\text{conv2}$  与  $\text{conv3}$  均是大小为

$1 \times 1$  的卷积核,  $\text{Softmax}$  决定拓展的维度。以此来重建统计特征  $S$ ,且  $L' \in R^{N \times C_2}$ 。可以发现,特征维度由  $C_1$  拓展为了  $C_2$ 。最后,将  $L'$  重新整形得到输出特征  $O$ 。

### 3.3 损失函数

分类损失。对类标签进行建模,本文使用多分类交叉熵定义分类损失  $L_C$ :

$$L_C = -\frac{1}{N} \sum_{i=1}^M \sum_{c=1}^M y_{ik} \ln(p_{ic}) \quad (5)$$

其中,  $M$  表示故障类别(包括健康状态)的数量,  $y_{ik}$  取 0 或 1, 样本  $i$  的真实类别等于  $c$  取 1, 否则取 0,  $p_{ic}$  表示样本  $i$  属于类别  $c$  的概率。  $L_C$  越小, 表示 DASEM 中分类器对该样本的分类效果越好, 即预测正确的概率越大。

域鉴别损失。对域标签进行建模, 本文使用二分类交叉熵定义域鉴别损失  $L_D$ :

$$L_D = -\frac{1}{N} \sum_i [y_i \ln(p_i) + (1-y_i) \ln(1-p_i)] \quad (6)$$

其中,  $y_i$  取 0 或 1, 样本  $i$  为正类时取 1, 为负类时取 0,  $p_i$  表示样本  $i$  预测为正类的概率。  $L_D$  越小, 表示 DASEM 中域鉴别器对该样本的鉴别效果越好, 即预测正确的概率越大。

最大均值差异。对数据结构进行建模, 度量的本质是计算源域和目标域在特征空间上的区别, 通过缩小两个领域间的差异来减少目标域的泛化误差。本文使用最大均值差异  $L_{MMD}$  来衡量源域与目标域之间的特征分布差异, 计算式如式(7)所示:

$$L_{MMD[F, s, t]} = \sup_{\|f\|_{\mathcal{H}} \leq 1} (E_s[f(x_s)] - E_t[f(x_t)]) \quad (7)$$

其中,  $x_s$  和  $x_t$  分别表示源域和目标域,  $E_s$  和  $E_t$  表示期望,  $f(\mathcal{X})$  表示将参数映射至高阶的函数,  $\|f\|_{\mathcal{H}} \leq 1$  表示在再生希尔伯特空间中的范数应该小于等于 1,  $\sup$  求得的上界作为 MMD 的值。

本文所提模型总的损失函数为:

$$L_{Total} = L_C - \alpha \times L_D + \beta \times L_{MMD[F, s, t]} \quad (8)$$

其中,  $\alpha$  和  $\beta$  分别为  $L_D$  和  $L_{MMD[F, s, t]}$  的权重, 可由梯度逆转层来确定。

## 4 实验

本文在公开的西储大学轴承数据集和江南大学轴承数据集上分别进行多组交叉跨域任务的实验, 以此验证在可变工况下, 本文所提智能故障诊断模型 DASEM 的有效性。

### 4.1 数据集及数据处理

1) 西储大学轴承数据集。该装置平台由驱动电机、轴、变速箱和负载部件组成。变速箱和负载部件分别控制装置平台在运行时电机的转速和电机提供的马力。其中, 电机预设转速的范围为 1 720 rpm ~ 1 797 rpm, 预设马力的范围为 0 ~ 3 hp。在轴承的内滚道、滚珠和外滚道上, 使用电火花加工 EDM 技术进行故障播种, 人为制造出直径长度在 0.007 ~ 0.040 in 范围内的故障, 并将各类故障程度和健康无损的轴承重新安装到测试电机上, 传感器以 10 240 Hz 的频率采样振动信号, 以滑动窗口的方式分割信号, 形成子样本。规定滑动窗口的长度为 1 024, 滑动过程中不允许重叠。

以电机不同转速和所提供大小不一的马来模拟实际生产中由于设备磨损老化、外部噪声干扰等所产生的变工况环境。每种工况中数据的特征分布各不相同。本实验设置 4 种工况环境: 1 797 rpm 的电机转速和 0 hp 的电机负载; 1 772 rpm 的电机转速和 1 hp 的电机负载; 1 750 rpm 的电机转速和 2 hp 的电机负载; 1 730 rpm 的电机负载和 3 hp 的电机负载。同时, 设置 10 种轴承健康状态: 3 种故障直径分别分布在 3 个部位(内滚道、滚珠和外滚道), 即有 9 种类型故障状态, 此外

还有 1 种完全健康的状态。

2) 江南大学轴承数据集。江南大学采用的装置平台仅由驱动电机、轴、变速箱组成, 最终实验采用的电机预设转速为 600 rpm、800 rpm 以及 1 000 rpm, 即设置 3 种不同的模拟的工况环境。分别在轴承的内滚道、滚珠以及外滚道人为制造 3 类故障(不再细分故障的直径大小), 加上完全健康状态类型, 共有 4 种轴承健康状态。传感器以 50 kHz 的频率采样振动信号, 以滑动窗口分割原始振动信号的方式生成子样本。

### 4.2 实验过程描述

我们将数据集的  $n$  个工况命名为 0 ~ ( $n-1$ ) 个域, 各个域之间交叉迁移, 即有  $n(n-1)$  个跨域任务。同时, 我们规定从  $a$  域迁移到  $b$  域记为  $Q_{a \rightarrow b}$ , 从  $b$  域迁移到  $a$  域记为  $Q_{b \rightarrow a}$ , 且总是从源域迁移到目标域。源域和目标域二者共同学习相同的特征分布映射。

预设学习周期为 300 轮, 前 50 轮仅输入源域数据, 初步学习到精度较低的分类器, 之后加入目标域数据并激活域鉴别器。总损失函数由分类损失、域鉴别损失和描述特征分布空间差异的度量三者共同构成, 经过反向传播不断优化, 使得分类器在特征提取器和域鉴别器的对抗中成长。

### 4.3 实验结果分析

西储大学轴承数据集在实验中使用到了 4 个域, 共有 12 个跨域故障诊断任务; 江南大学轴承数据集在实验中使用到了 3 个域, 共有 6 个跨域诊断任务。我们对每个任务统一执行 10 次, 每次执行过程中会经历 300 轮的数据更新, 记录效果最好的模型参数, 并在 10 次完整执行后取分类准确率的平均值。

1) 对比实验。表 1 和表 2 分别列出了本文提出的模型与一些常用的轴承故障诊断模型, 如 CNN, Resnet<sup>[16]</sup>, BiLSTM<sup>[17]</sup>, DAGCN<sup>[18]</sup>, CORAL<sup>[19]</sup> 等, 在西储大学轴承数据集和江南大学轴承数据集上的实验对比结果。易知, 本文提出的模型 DASEM 在总体上存在着显著的分类优势, 在西储大学轴承数据集与江南大学轴承数据集上各跨域任务的平均准确率分别达到了 94.90% 与 93.15%, 且在个别的分类任务上也有着极为优秀的表现。

表 1 西储大学轴承数据集上的分类准确率比较

Table 1 Comparison of classification accuracy on CWRU bearing dataset (%)

任务	CNN	Resnet	BiLSTM	DAGCN	CORAL	DASEM
$Q_{0 \rightarrow 1}$	<b>99.23</b>	98.47	71.65	98.08	96.70	<b>99.23</b>
$Q_{0 \rightarrow 2}$	97.70	90.42	67.43	<b>99.23</b>	98.47	<b>99.23</b>
$Q_{0 \rightarrow 3}$	94.25	90.42	66.28	93.10	92.72	<b>96.17</b>
$Q_{1 \rightarrow 0}$	79.31	81.23	56.70	78.93	81.23	<b>81.61</b>
$Q_{1 \rightarrow 2}$	98.05	<b>100.00</b>	61.36	99.89	99.68	<b>100.00</b>
$Q_{1 \rightarrow 3}$	96.75	<b>100.00</b>	71.75	98.05	97.73	<b>100.00</b>
$Q_{2 \rightarrow 0}$	81.23	81.61	56.70	80.84	81.23	<b>81.61</b>
$Q_{2 \rightarrow 1}$	97.08	<b>100.00</b>	65.58	98.05	96.43	99.68
$Q_{2 \rightarrow 3}$	97.73	<b>100.00</b>	59.42	98.70	98.05	<b>100.00</b>
$Q_{3 \rightarrow 0}$	81.23	77.01	53.64	<b>81.61</b>	<b>81.61</b>	<b>81.61</b>
$Q_{3 \rightarrow 1}$	90.26	99.35	62.01	93.18	92.53	<b>99.68</b>
$Q_{3 \rightarrow 2}$	93.18	<b>100.00</b>	60.39	96.75	95.45	<b>100.00</b>
平均值	92.17	93.21	62.74	93.07	92.65	<b>94.90</b>

表2 江南大学轴承数据集上的分类准确率比较

Table 2 Comparison of classification accuracy on bearing dataset of Jiangnan University

任务	CNN	Resnet	BiLSTM	DAGCN	CORAL	DASEM
$Q_{0 \rightarrow 1}$	93.37	86.86	74.32	92.42	56.54	<b>95.26</b>
$Q_{0 \rightarrow 2}$	90.78	93.00	85.32	90.14	56.25	<b>93.21</b>
$Q_{1 \rightarrow 0}$	89.98	<b>92.49</b>	47.10	85.77	57.05	89.05
$Q_{1 \rightarrow 2}$	95.69	<b>97.95</b>	95.73	96.59	61.57	95.84
$Q_{2 \rightarrow 0}$	86.38	81.91	59.22	84.04	51.91	<b>87.17</b>
$Q_{2 \rightarrow 1}$	95.64	96.25	93.86	95.60	59.10	<b>98.36</b>
平均值	91.97	91.41	75.91	90.76	57.07	<b>93.15</b>

2) 消融实验。为了证明本文模型 DASEM 中各个部分对模型性能的关键影响,我们进行了消融实验验证。在 DASEM 的基础上,去除特征遗忘和 QCO-EM,实验结果如表 3 和表 4 所列。

表3 西储大学轴承数据集上的消融实验结果

Table 3 Results of ablation experiments on CWRU bearing dataset

任务	去除 Forget	去除 QCO-EM	去除 Forget & QCO-EM	DASEM
$Q_{0 \rightarrow 1}$	98.85	94.92	98.08	99.23
$Q_{0 \rightarrow 2}$	97.70	99.61	99.23	99.23
$Q_{0 \rightarrow 3}$	97.32	94.14	93.10	96.17
$Q_{1 \rightarrow 0}$	78.93	76.17	78.93	81.61
$Q_{1 \rightarrow 2}$	100.00	99.22	99.89	100.00
$Q_{1 \rightarrow 3}$	100.00	99.61	98.05	100.00
$Q_{2 \rightarrow 0}$	79.69	79.30	80.84	81.61
$Q_{2 \rightarrow 1}$	99.68	93.75	98.05	99.68
$Q_{2 \rightarrow 3}$	100.00	97.66	98.70	100.00
$Q_{3 \rightarrow 0}$	75.10	79.56	81.61	81.61
$Q_{3 \rightarrow 1}$	99.68	96.48	93.18	99.68
$Q_{3 \rightarrow 2}$	100.00	99.22	96.75	100.00
平均值	93.91	92.47	93.07	94.90

表4 江南大学轴承数据集上的消融实验结果

Table 4 Results of ablation experiments on bearing dataset of Jiangnan University

任务	去除 Forget	去除 QCO-EM	去除 Forget & QCO-EM	DASEM
$Q_{0 \rightarrow 1}$	94.91	81.23	92.47	95.26
$Q_{0 \rightarrow 2}$	93.17	69.11	90.14	93.21
$Q_{1 \rightarrow 0}$	86.31	75.26	85.77	89.05
$Q_{1 \rightarrow 2}$	95.96	85.84	96.59	95.84
$Q_{2 \rightarrow 0}$	85.74	74.06	84.04	87.17
$Q_{2 \rightarrow 1}$	97.73	93.52	95.60	98.36
平均值	92.30	79.79	90.76	93.15

从表 3 和表 4 中可以发现,去除 DASEM 中某个或某几个子网络,会导致故障诊断精度有所下降。具体地讲,当只去除特征遗忘时,会使得数据在传入图卷积时维度过大,导致运算时间过长,同时故障诊断效果不佳。当只去除 QCO-EM 时,会使得模型学习不到演变自原始振动信号中的全局统计特性,致使模型学习的视角单一,效果不尽人意;当二者同时被去除时,其故障诊断效果明显弱于仅去除特征遗忘时的情况。

同时,我们使用数据可视化工具 t-SNE(t-distributed Stochastic Neighbor Embedding,t 分布-随机邻近嵌入)方法,对模型提取到的特征进行了可视化展示。图 3 和图 4 分别给出了西储大学数据集和江南大学数据集数据映射前、后的特征

分布对比。我们发现,经特征提取器映射后的同类不同域的故障数据处于同一特征空间中,且不同故障类型的数据特征空间分散。




图3 西储大学数据映射前、后的特征分布对比

Fig. 3 Comparison of feature distribution before and after data mapping on CWRU dataset

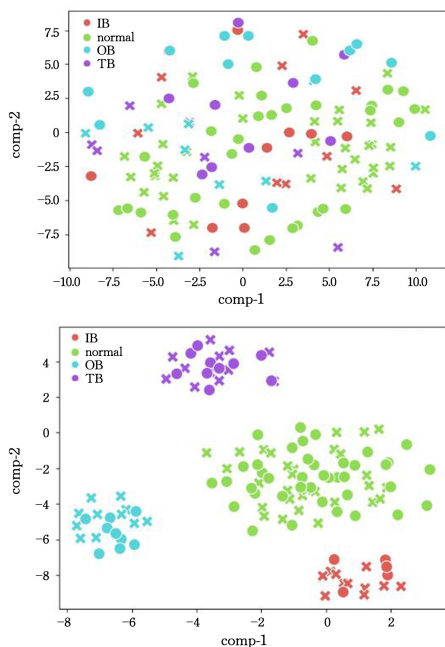


图4 江南大学数据映射前、后的特征分布对比


Fig. 4 Comparison of feature distribution before and after data mapping on Jiangnan University dataset

**结束语** 本文通过对类标签、域标签、数据结构三者建模,提出了一种基于域对抗并可以同时学习到原始振动信号结构模式和统计特性的模型 DASEM,用于对滚动轴承的跨域故障诊断。本文的结论总结如下:1)DASEM 使用量化和计数算子-增强模型和一维卷积神经网络分别提取振动信号

的统计特性和结构模式的特征;2)DASEM 采用由多个逻辑门组合形成的特征遗忘子网络对双路径特征做降维处理;3)DASEM 末端的图卷积神经网络可以将数据的信息表达得更全面;4)DASEM 在特征提取器与域鉴别器的博弈中实现了跨域故障诊断。本文提出的方法在西储大学轴承数据集和江南大学轴承数据集上取得了较好的分类诊断效果。尽管振动信号的统计特性丰富了特征提取的视角,但个别任务仍难以有效地进行跨域诊断,未来将进一步探究域对抗结构下的故障诊断问题。

## 参 考 文 献

- [1] PEI S C, YE H M, LUO T L. Fractional Fourier series expansion for finite signals and dual extension to discrete-time fractional Fourier transform[J]. *IEEE Transactions on Signal Processing*, 1999, 47(10): 2883-2888.
- [2] KUMAR R, VERMA P K. Signal Space Estimation: Application to Subspace Spectrum Analysis[C]// *Proceedings of the Ambient Communications and Computer Systems*. Springer, 2018.
- [3] PALUPI I R, RAHARJO W. The utilization of signal analysis by using short time Fourier transform[C]// *Proceedings of the RSF Conference Series: Engineering and Technology*. 2021.
- [4] PENG Z, PETER W T, CHU F. A comparison study of improved Hilbert-Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing[J]. *Mechanical Systems and Signal Processing*, 2005, 19(5): 974-988.
- [5] OSADCHIY A, KAMENEV A, SAHAROV V, et al. Signal processing algorithm based on discrete wavelet transform[J]. *Designs*, 2021, 5(3): 41.
- [6] ZAMAN S, ISLAM R. Classification of FNIRS using Wigner-ville distribution and CNN[J]. *International Journal of Image, Graphics and Signal Processing*, 2021, 13(5): 1-13.
- [7] LU N, YIN T. Transferable common feature space mining for fault diagnosis with imbalanced data[J]. *Mechanical Systems and Signal Processing*, 2021, 156: 107645.
- [8] XIAO Y, WANG J, HE Z, et al. Deep transfer learning with metric structure for fault diagnosis[J]. *Knowledge-Based Systems*, 2022, 256: 109826.
- [9] GOLDT S, MÉZARD M, KRZAKALA F, et al. Modeling the influence of data structure on learning in neural networks: The hidden manifold model[J]. *Physical Review X*, 2020, 10(4): 041044.
- [10] ZHENG H, YANG Y, YIN J, et al. Deep domain generalization combining a priori diagnosis knowledge toward cross-domain fault diagnosis of rolling bearing[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 70: 3501311.
- [11] ZHANG B, LI W, LI X L, et al. Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks[J]. *IEEE Access*, 2018, 6: 66367-66384.
- [12] SHAO S, MCALEER S, YAN R, et al. Highly accurate machine fault diagnosis using deep transfer learning[J]. *IEEE Transactions on Industrial Informatics*, 2018, 15(4): 2446-2455.
- [13] CAO P, ZHANG S, TANG J. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning[J]. *IEEE Access*, 2018, 6: 26241-26253.
- [14] 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.
- [15] ZHU L, JI D, ZHU S, et al. Learning statistical texture for semantic segmentation[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021.
- [16] WEN L, LI X, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50[J]. *Neural Computing and Applications*, 2020, 32: 6111-6124.
- [17] SHI J, PENG D, PENG Z, et al. Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks[J]. *Mechanical Systems and Signal Processing*, 2022, 162: 107996.
- [18] LI T, ZHAO Z, SUN C, et al. Domain adversarial graph convolutional network for fault diagnosis under variable working conditions[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 3515010.
- [19] LI X, ZHANG Z, GAO L, et al. A new semi-supervised fault diagnosis method via deep CORAL and transfer component analysis[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2021, 6(3): 690-699.



**ZHU Yuhao**, born in 1997, postgraduate. His main research interests include fault diagnosis and machine learning.



**ZHANG Yong**, born in 1975, Ph.D, professor, Ph.D supervisor, is a member of CCF (No. 12677S). His main research interests include machine learning and data mining.