

基于多尺度子领域自适应的轴承故障诊断研究

贡莹莹, 朱晓娟

安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001

摘要:目的 针对轴承在不同工况下的振动信号特征分布显著差异,以及单一的感受野可能无法有效涵盖多尺度故障特征识别问题,提出一种多尺度子领域自适应轴承故障诊断方法。方法 首先,利用局部最大均值差异(LMMD)量化分析不同工况下同类轴承故障样本在特征空间中的分布差异,以提取域不变特征,确保无论在何种工况下都能准确捕获轴承的故障特征;其次,在特征提取阶段构建多尺度膨胀卷积网络架构,采用多个感受野确保每个工况的最佳特征提取范围,避免因感受野大小受限而导致故障信息遗漏的问题;然后,为进一步提升诊断模型对各工况下子类故障特征的识别能力,引入 SE 注意力机制。赋予各尺度特征不同的关注度权重,从而更加关注与故障诊断紧密联系的特征信息并抑制冗余信息,增强对各工况下子类故障特征表达的一致性和有效性。结果 最后,在公开数据集下进行实证分析,实验结果表明:所提出方法在各工况下的平均诊断精度约 98%。结论 证实了该方法的有效性和优势,相较于其他现有诊断技术,展现出更高的诊断性能和可靠性。

关键词:变工况;子领域自适应;故障诊断;轴承

中图分类号:TH133.33 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2026.0004.013

Research on Bearing Fault Diagnosis Based on Multiscale Subdomain Adaptation

GONG Yingying, ZHU Xiaojuan

School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, Anhui, China

Abstract: Objective A bearing fault diagnosis method based on multiscale subdomain adaptation is proposed to address the significant differences in the distribution of vibration signal features of bearings under varying operating conditions and the potential inadequacy of a single receptive field in effectively capturing multi-scale fault features. **Methods** First, local maximum mean discrepancy (LMMD) was employed to quantify the distribution differences of bearing fault samples from the same category within the feature space under different operational conditions. This step was crucial for extracting domain-invariant features, which ensured the accurate capture of fault characteristics regardless of the varying operational states. Second, a multi-scale dilated convolutional network architecture was constructed during the feature extraction stage. This design utilized multiple receptive fields to secure the optimal feature extraction scope for each operating condition, thereby preventing the omission of critical fault information due to a limited receptive field size. Subsequently, a squeeze-and-excitation (SE) attention mechanism was introduced to further enhance the model's capability to discern sub-class fault features across all conditions. This mechanism assigned varying weights of attention to features from

收稿日期:2024-04-26 **修回日期:**2024-07-07 **文章编号:**1672-058X(2026)04-0096-08

基金项目:安徽高校省级自然科学基金重点项目(KJ2020A0300)资助。

作者简介:贡莹莹(1999—),女,江苏镇江人,硕士研究生,从事智能故障诊断研究。

通信作者:朱晓娟(1978—),女,安徽淮南人,博士,副教授,从事智能物联网与智能故障诊断研究。Email:xjzhu@ust.edu.cn.

引用格式:贡莹莹,朱晓娟.基于多尺度子领域自适应的轴承故障诊断研究[J].重庆工商大学学报(自然科学版),2026,43(4):96-103.

Gong Yingying, Zhu Xiaojuan. Research on bearing fault diagnosis based on multiscale subdomain adaptation[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2026, 43(4): 96-103.

different scales, enabling the model to focus more intensively on features closely linked to fault diagnosis while suppressing redundant information. This process strengthened the consistency and effectiveness of the sub-class fault feature representation under various operating conditions. **Results** Finally, an empirical analysis was conducted on a public dataset. The experimental results demonstrated that the proposed method achieved an average diagnostic accuracy of approximately 98% across all operating conditions. **Conclusion** These findings confirm the effectiveness and superiority of the proposed method. Compared with other existing diagnostic techniques, the proposed method exhibits higher diagnostic performance and greater reliability.

Keywords: variable operating condition; subdomain adaptation; fault diagnosis; bearing

轴承作为旋转机械的核心部件,其健康状况监测与故障早期诊断至关重要^[1-2]。尽管深度学习在轴承故障诊断中表现出色,但存在数据分布广泛、可用性有限的问题。模型训练通常假定训练与测试数据同分布^[3],然而实际工况变化、设备差异可能导致测试数据分布变化,影响诊断准确性^[4]。同时,采集故障数据耗时,而长时间的高温、高转速和高负载环境也会导致数据特征分布不均^[5],降低模型泛化能力。

引入迁移学习方法解决故障诊断中标记数据不足的问题,利用相关源域的知识进行预测,更好地学习了目标域的特征^[6],实现不同任务间的迁移。基于领域自适应的迁移学习在变工况故障诊断中备受关注,其中距离的测量对两域关系至关重要,Lu等^[7]提出了一种具有领域自适应的深度网络模型,利用自编码器来提取故障特征,并采用MMD计算源域和目标域之间的分布差异,并将其作为优化目标;Yu等^[8]设计条件对抗性领域自适应网络确保模型适应不同领域数据分布;Chen等^[9]在参数模型基础上引入对抗思想对齐两域的数据边界分布获取域不变特征。这些方法在整体分布对齐上取得成果,有效地提高了模型对不同领域数据的适应性。然而,这些方法没有考虑同一类别下不同域中子域间关系可能导致细粒度信息丢失的问题^[10]。这一问题由Liu等^[11]提出的深度对抗子域自适应网络所解决,实现相同故障类别子域分布的对齐,取得了出色的诊断性能。这些方法的优点在于通过领域自适应和对抗性思想,有效地提高了模型在不同领域上的泛化能力,进一步提高了故障诊断的准确性和可靠性,但是这些方法也存在一些不足,比如训练速度较慢、计算成本较高等问题。

为了克服单一感受野在不同工况下提取有效故障信息的局限性,本文提出了多尺度子领域自适应(Multi-scale subdomain adaptation, MSDAN)的方法。该方法

通过在特征提取模块进行优化,增强对不同工况下轴承故障特征的识别效果,特别是处理多尺度特征的能力。具体而言,该方法采用多尺度膨胀卷积捕获故障特征,并结合SE注意力机制,自适应地为不同尺度特征分配通道权重,既强化了信息特征又抑制了冗余特征,从而实现更准确的故障分类。

1 相关理论

1.1 子领域自适应

在解决变工况轴承故障识别问题时,领域自适应方法将不同数据集映射到共享特征空间进行对齐,从而减少分布差异,提升模型泛化能力。全局域自适应使总体分布相似,但可能导致错误分类,如图1(a)所示。而子领域自适应更专注于准确对齐相关子领域的分布,利用模型的预测概率输出作为伪标签进行目标域子领域划分,使得整体和局部分布都更相似,如图1(b)所示。




图1 领域自适应与子领域自适应

Fig. 1 Domain adaptation and subdomain adaptation

1.2 膨胀卷积

膨胀卷积又称空洞卷积^[12],是一种通过增加感受野而不增加参数量的卷积操作,利用膨胀率参数调节卷积核像素之间的间隔,从而提高网络对全局特征的感知能力。

对于一个 3×1 的卷积核,膨胀率为1时,卷积核大小与普通卷积相同;膨胀率为2和3时,映射范围分别扩展到 5×1 和 7×1 。采用不同膨胀率的并行分支可以

捕获不同尺度下的故障特征,从而更全面地获取输入数据的信息。

1.3 SE 注意力机制

注意力机制^[13]模拟人类的关注能力,使模型能够集中关注重要信息,抑制冗余信息,提高学习和表现能力。

如图 2 所示,使用挤压激励(SE)注意力机制在轴承特征提取中,能够根据不同尺度的特征权重贡献整体模型性能,并获取细粒度信息,减少对冗余特征的过度关注。




图 2 SE 注意力机制

Fig. 2 SE attention mechanism

1.4 局部最大均值差异(LMMD)

LMMD^[14]是为了解决 MMD 在全局域自适应中忽略不同类别子域分布的问题而提出的。LMMD 专注于量化两个域中子领域的分布差异,通过生成目标域的伪标签来综合考虑子域分布相似性,从而减小源域和目标域之间的差异,提升模型泛化能力。LMMD 的计算如下:

$$\hat{d}_H(p, q) = \frac{1}{C} \sum_{c=1}^C \left\| \sum_{x_i^s \in D_s} \omega_i^{sc} \varphi(x_i^s) - \sum_{x_j^t \in D_t} \omega_j^{tc} \varphi(x_j^t) \right\|_H^2 \quad (1)$$

式(1)中, ω_i^{sc} 和 ω_j^{tc} 分别代表样本 x_i^s 和 x_j^t 在故障类别 c 下的权重,并且 $\sum_{i=1}^{n_s} \omega_i^{sc} = 1$, $\sum_{j=1}^{n_t} \omega_j^{tc} = 1$ 以及 $\sum_{x_i \in D} \omega_i^c \varphi(x_i)$ 属于故障类别 c 的加权和。其中,权重 ω_i^c 的计算方式如下:

$$\omega_i^c = \frac{y_{ic}}{\sum_{(x_j, y_j) \in D^c} y_{ic}} \quad (2)$$

定义 y_{ic} 代表向量 y_i 对于第 c 类别标签的对应值。对于源域,运用式(2)推导样本真实标签 y_i^s ,进而计算加权系数 ω_i^{sc} 。对于无标签的目标域数据,采用伪标签 $\hat{y}_i^t$ 来计算目标域样本在训练中的权重 ω_j^{tc} 。在高层网络结构中,通过确定第 l 层的激活值 z^l ,其包含 n_s 个源域标记样本遵循概率 p 和 n_t 个目标域未标记样本遵循概率 q 。由此推出 LMMD 的定义为

$$\hat{d}_l(p, q) = \frac{1}{C} \sum_{c=1}^C \left[\sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_i^{sc} \omega_j^{tc} k(z_i^{sl}, z_j^{tl}) + \sum_{i=1}^{n_t} \sum_{j=1}^{n_t} \omega_i^{tc} \omega_j^{tc} k(z_i^{tl}, z_j^{tl}) - 2 \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_i^{sc} \omega_j^{tc} k(z_i^{sl}, z_j^{tl}) \right] \quad (3)$$

2 多尺度子领域自适应

多尺度子领域自适应(Multi-scale subdomain adaptation, MSDAN)的方法旨在解决变工况下轴承振动数据特征分布差异和感受野固定导致无法捕捉多尺度特征的问题。首先,通过卷积和最大池化将原始振动信号转化为基础特征图,避免在膨胀卷积层中直接提取特征出现的问题。其次,采用多个感受野特征提取器获取多尺度特征,并利用 SE 注意力机制有效地筛选并抑制非关键特征的干扰,将处理过的特征放入分类器中获取目标域的预测标签。然后,通过将实际标签和预测标签进行对比,计算 LMMD 来缩减各领域之间的分布差距,旨在发掘并提取在不同领域间保持稳定不变的特征。最后,通过反复迭代获得最佳参数,将训练后的模型应用于轴承故障诊断。

2.1 多尺度特征提取模块

故障诊断中常用卷积神经网络进行特征提取。随工况变化,网络深度增加时可能无法捕捉不同尺度振动信号中的信息,因此采用多尺度卷积神经网络来解决这一问题。Qin 等^[15]引入多尺度迁移投票机制,利用不同卷积核和池化操作的多个分支提取迁移性特征,应用于轴承和齿轮箱跨域故障诊断。Wu 等^[16]着重研究卷积核大小的重要性,提出多尺度卷积神经网络来更完整获取时频信息。为解决增大感受野可能导致的参数膨胀和训练困难问题,引入了多尺度膨胀卷积模块。该模块具备动态调整能力,能够在各种运行条件下找到最适宜的感受野,适用于不同工况下的轴承故障诊断。

本文特征提取模块如图 3 所示。每个分支使用特定膨胀率构建卷积核,提取特定尺度特征。并行处理多个尺度相同输入特征,实现对不同尺度信息的有效整合,形成综合特征空间^[17]。零填充策略避免额外计算复杂性,有助于防止过拟合,捕获更广泛特征,确保了膨胀卷积输出的特征图形状与膨胀率无关。在 3 个并行分支中,膨胀率分别设置为 1、2 和 3。为防止导致局部信息丢失,膨胀率不宜过大,膨胀卷积核的大小均一致,同时存在 Padding 和步长均为 1。最终通过 Concat 连接 3 个分支的输出特征向量,形成特征输出图,构建了一个完整的多尺度膨胀卷积模块。




图 3 多尺度膨胀卷积特征提取模块

Fig. 3 Multi-scale dilated convolutional feature extraction module

2.2 MSDAN 网络模型

MSDAN 结构模型如图 4 所示,包含特征提取器和分类器两部分。在特征提取阶段,采用多尺度膨胀卷积网络来提取域不变特征,特征提取器结构如图 5 所示。具体来说,先将一维原始振动信号输入卷积层,并接入最大池化层以减少信息冗余。引入 4 个多尺度膨胀卷积模块,这些模块能够在不同层次的空间范围内扩展对故障信号特征的感知视野,实现对多尺度特征的有效抓取。为进一步提取特征信息,每个模块后接入 SE 注意力机制模块,对特征图进行加权处理以强调细粒度特征。最后,通过平均池化层实现降维和防止过拟合,并通过全连接层对处理后的特征向量进行整合和分类决策,从而得出准确的故障类型预测结果。




图 4 MSDAN 网络结构

Fig. 4 MSDAN network architecture




图 5 特征提取器结构

Fig. 5 Structure of feature extractor

分类器由全连接层组成,采用 Softmax 函数作为激活单元进行故障分类。网络采用 LMMD 算法测量不同工况下域间分布差异的损失。训练过程中,存在两个优化目标分别为最小化源域分类误差 L_{cls} 以及最小化子领域自适应误差 L_{lmmd} ,具体表达式如下:经过分类处理的数据得到预测标签为 $\hat{Y}^s$,为了衡量其分类效果,将 $\hat{Y}^s$ 与对应的真实标签 Y^s 结合,运用交叉熵损失函数进行计算,得出分类误差 L_{cls} 为

$$L_{cls} = \min \frac{1}{n_s} \sum_{i=1}^{n_s} J(\hat{Y}^s, Y^s) \quad (4)$$

同时,将源域真实标签 $\hat{Y}^s$ 与目标域生成的预测标签 $\hat{Y}^t$ 相结合,进而量化两域间的损失,误差 L_{lmmd} 为

$$L_{lmmd} = \alpha \mu \sum_{l \in L} \hat{d}_l(p, q) \quad (5)$$

根据式(4)和式(5),综合损失函数定义为 $L_{total} = L_{cls} + L_{lmmd}$,式(4)中 $J(\cdot, \cdot)$ 表示为分类任务评价标准的交叉熵损失函数, $\hat{d}_l(p, q)$ 参照式(3)计算得到的用于衡量子领域适应性的指标函数。为了实现模型优化,设置 $L=1$,并引入一个控制子领域特征分布差异的重要超参数 α ,其取值大于零,此参数调节不同工况下的特征适应性程度。经过一系列实验探索,确定了有效的超参数值 μ ,即 $\mu = 0.3$, α 的表达式如下:

$$\alpha = \frac{2}{1 + \exp^{-10 \cdot t/T}} - 1 \quad (6)$$

式(6)中, t 为当前训练迭代次数, T 为训练总迭代次数。

2.3 故障诊断整体流程

本文方法流程包括 3 部分,如图 6 所示。




图 6 故障诊断流程

Fig. 6 Flowchart of the fault diagnosis process

(1) 数据预处理。对收集到的一维原始振动信号进行处理,生成基础特征图。按比例划分为训练集和测试集,并对数据进行归一化。

(2) 模型训练。利用诊断结果与实际值进行损失值计算,采用 SGD 算法,对模型进行迭代训练,直至达到最优情况,计算出数据的精确度。

(3) 故障诊断。使用训练后的模型对目标域样本进行故障分类,输出诊断结果。

如表 1 所示,模型参数结构详见文献[18]。

表 1 MSDAN 模型参数

Table 1 MSDAN model parameters

名 称	核尺寸/步长	输入通道	输出通道
卷积层	25×1/1	2 048	—
池化层	8×1/8	2 048	256
多尺度 DR 为 1	3×1/1	256	256
DR 为 2	3×1/1	256	256
DR 为 3	3×1/1	256	256
注意力机制		$r=0.5$	
池化层	2×1/2	256	128
全连接层	—	128	64
Softmax		10×1	

3 仿真实验与结果分析

3.1 CWRU 实验数据集介绍

本文选用凯斯西储大学公开数据集,如图 7 所示,通过在 12 kHz 的采样频率下进行振动数据采集。根据不同的转速和负载条件,生成了 4 个不同工况的数据

集,分别命名为 A、B、C 和 D。借助电火花加工方式模拟产生单点故障案例,每个工况下共有 10 种不同的故障状态,用标签 0~9 表示,详细信息如表 2 所示。




图 7 凯斯西储大学轴承试验台

Fig. 7 CWRU bearing testbed

表 2 单工况下的 10 种状态信息描述

Table 2 Description of 10 statuses under a single operating condition

类 型	轴承损伤 直径/cm	标 签	数 量
正常状态(N)	无	0	100
内圈故障 (IRF)	0.018	1	100
	0.036	2	100
	0.053	3	100
外圈故障 (ORF)	0.018	4	100
	0.036	5	100
	0.053	6	100
滚动体故障 (RF)	0.018	7	100
	0.036	8	100
	0.053	9	100

3.2 结果分析

为验证 MSDAN 在变工况下故障诊断的优势,使用其他模型进行对比分析,包括卷积神经网络(CNN)方法、深度自适应网络(DAN)^[18]方法、深度子领域自适应(DSAN)^[14]以及深度多尺度子领域自适应(MSDAM)^[19]方法。模型采用 SGD 优化算法,动量设置为 0.9,采用动态学习率下降策略,初始值设置为 0.001,最终为 1×10^{-5} 。运行环境为 Python3.8.18 + Pytorch2.0.1, GPU 为 NVIDIA GeForce RTX 4060, batchsize 设为 32, epoch 为 30。

本文模型及其余模型诊断精度如表 3 所示,特别

地,针对迁移任务的形式“ $A \rightarrow B$ hp”定义为:工况 A 的数据为源域,工况 B 的数据为目标域。评估这些模型性能的关键指标涵盖了总体精度、平均精度,以及通过混淆矩阵来细致分析各类别的识别能力。为了全面检验模型的泛化性能,在凯斯西储大学数据集的 4 个工况上进行 12 种跨工况诊断任务。

表 3 各模型的诊断精度对比

迁移任务	CNN	DAN	DSAN	MSDAM	MSDAN
$A \rightarrow B$ hp	85.7	92.5	94.4	93.4	96.8
$A \rightarrow C$ hp	70.5	95.4	96.5	97.8	98.5
$A \rightarrow D$ hp	75.0	96.7	93.4	98.6	97.5
$B \rightarrow A$ hp	75.1	93.7	97.6	95.5	98.6
$B \rightarrow C$ hp	81.1	97.5	96.4	98.1	98.4
$B \rightarrow D$ hp	88.7	96.5	97.7	97.6	99.5
$C \rightarrow A$ hp	78.3	98.9	96.5	97.5	98.5
$C \rightarrow B$ hp	87.8	91.0	96.3	93.5	96.7
$C \rightarrow D$ hp	71.2	97.9	98.7	98.6	99.6
$D \rightarrow A$ hp	72.1	75.9	96.0	96.9	96.1
$D \rightarrow B$ hp	76.1	77.4	95.8	96.8	97.6
$D \rightarrow C$ hp	88.8	92.6	96.9	98.9	99.5
平均值	79.2	92.1	96.4	96.9	98.1

(1) 在这 12 个迁移任务中,本文模型的诊断结果平均值为 98.1%,相比其他四种诊断方法,该方法在跨域故障诊断中具有较好的泛化能力,可以学习更多的可迁移故障特征。

(2) 综合对比表 3,CNN 表现相对较差,仅 79.2%。因为当故障数据在不同工作条件下的分布形态各异时,模型的泛化性能可能会受到影响而减弱。DAN 有所提升,通过多核 MMD 对齐源域和目标域,但仅关注全局领域自适应,对跨域条件分布差异忽视,导致子领域混乱,产生分类误差。DSAN 在对齐子域分布方面取得 96.4%的平均诊断精度,捕捉类别的细粒度信息,但固定感受野限制适应不同工况下的故障信息提取需求。MSDAM 通过多尺度卷积提高平均诊断精度至 96.9%,但缺少注意力机制来抑制冗余,导致诊断结果低于本方法。

(3) 本文 MSDAN 方法不仅延续了有效挖掘各类故障精细表征的能力,还创新性地结合了多尺度空间

范围的特征提取技术,确保在各种运行条件变化时能够精确无误地抽取故障特征。同时,融入注意力模型来优化信息权重分配,从而提升整个故障识别系统的精准度。

(4) 通过数据集验证,图 8 显示训练阶段准确率曲线稳步上升,无明显波动,表明模型在学习过程中稳定提升,没有出现过度泛化或不稳定情况。同时,图 9 显示损失函数曲线迅速下降,接近零,说明本文方法性能更稳定。




图 8 模型诊断准确率

Fig. 8 Model diagnostic accuracy





图 9 模型诊断损失率

Fig. 9 Diagnostic loss rate of the model

(5) 经过模型训练,生成混淆矩阵。图 10 中可以清晰地看到每个故障类别的分类准确性以及可能存在的误分类情况。迁移任务 $C \rightarrow B$ hp 中,标签为 2 中的 1 个样本被错误分类为标签 7;标签为 7 中的 3 个样本被错误分类为标签 1 等等。其余的样本均能够被 100%正确地识别,进一步证明该方法具有较好的诊断能力。

图 10 迁移任务 $C \rightarrow B$ hp 的混淆矩阵Fig. 10 Confusion matrix for the migration task $C \rightarrow B$ hp

3.3 消融实验

为验证多尺度膨胀卷积模块、SE 注意力机制模块以及局部均值差异 (LMMD) 等部分的有效性,以工况 A 为源域,工况 B、C、D 为目标域进行一组消融实验,如表 4 所示。将不包含多尺度膨胀卷积模块、SE 注意力机制模块和 LMMD 的基准模型称为实验 1,将去掉多尺度卷积模块的 MSDAN 称为实验 2,去掉 SE 注意力机制模块的 MSDAN 称为实验 3,去掉 LMMD 的 MSDAN 称为实验 4。

表 4 消融实验诊断精度对比

Table 4 Comparison of diagnostic accuracy of

ablation experiments					/%
迁移任务	实验 1	实验 2	实验 3	实验 4	
$A \rightarrow B$ hp	85.7	94.6	92.1	90.6	96.8
$A \rightarrow C$ hp	70.5	95.5	94.4	92.4	98.5
$A \rightarrow D$ hp	75.0	96.8	93.6	91.6	97.5

根据表 4 的结果,可以得出以下结果:实验 1 作为基准模型,其准确度最低;在实验 2 中,在不采用多尺度膨胀卷积模块的情况下,诊断精度有所下降,这表明单一感受野在特征提取中存在局限性;实验 3 虽然采用了多尺度膨胀卷积模块以适应不同尺度的故障特征,但缺乏 SE 注意力机制的加持。信息筛选和权重分配不够有效,可能低估了关键故障特征的重要性,导致准确率下降;而实验 4 在设计上未采用 LMMD 方法来度量不同子领域的分布差异,而是单纯关注全局领域特征,导致准确率明显降低。

本文所提出的模型巧妙融合了多尺度膨胀卷积、SE

注意力机制及局部最大均值差异技术,成功解决了这些难题,实现了诊断精度的显著提升与优越性能展现。

3.4 模型有效性的可视化分析(t -SNE)

通过 t -SNE 可视化模型输入和输出结果,使用分布随机邻域嵌入将高维数据降维到 2 维^[20],如图 11 所示。初始阶段特征分布混乱,导致分离效果较差;随着网络深入,特征逐渐具有区分性;在多尺度特征融合阶段,同一类型的特征得到了较好的聚合,但不同类型的特征仍存在混淆。对比引入 SE 注意力机制前后的结果,可以发现同一故障类型特征在引入注意力机制后基本聚合,仅存在一些误差。这说明注意力机制有效提高了网络的特征学习和诊断可靠性,验证了多尺度特征融合和 SE 注意力机制的有效性。




图 11 特征可视化

Fig. 11 Feature visualization

4 结 论

为优化轴承故障诊断模型性能,提出了多尺度子领域自适应方法 (MSDAN)。该方法基于深度子域适应性框架,对特征提取进行两项关键改进:首先,采用多尺度膨胀卷积结构的模块,提取不同振动信号中的多尺度故障特征,克服单一感受野局限性,有效提升特征多元化表现能力。其次,引入 SE 注意力机制作为进一步优化措施,智能调整通道权重分配,增强信息特征、抑制冗余特征,提高特征代表性。综合而言,MSDAN 方法能精细提取各类故障特征,减小跨域数据分布差异,并利用多重感知视野获取全面故障信息。

参考文献 (References):

- [1] Zhao Z, Wu J, Li T, et al. Challenges and opportunities of AI-enabled monitoring, diagnosis & prognosis: a review[J]. Chinese Journal of Mechanical Engineering, 2021, 34(1): 56-66.

- [2] Ju Y, Tian X, Liu H, et al. Fault detection of networked dynamical systems: a survey of trends and techniques[J]. *International Journal of Solids and Structures*, 2021, 52(16): 3390–3409.
- [3] 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*, 2021, 17(5): 3488–3496.
- [4] Chen X, Yang R, Xue Y, et al. Deep transfer learning for bearing fault diagnosis: a systematic review since 2016[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72(6): 1–21.
- [5] Wen P, Li X, Hou N, et al. Distributed recursive fault estimation with binary encoding schemes over sensor networks[J]. *Systems Science & Control Engineering*, 2022, 10(1): 417–427.
- [6] 董绍江, 朱朋, 裴雪武, 等. 基于子领域自适应的变工况下滚动轴承故障诊断[J]. *吉林大学学报(工学版)*, 2022, 52(2): 288–295.
Dong Shaojiang, Zhu Peng, Pei Xuewu, et al. Fault diagnosis of rolling bearing under variable operating conditions based on subdomain adaptation[J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2022, 52(2): 288–295.
- [7] Lu W, Liang B, Cheng Y, et al. Deep model based domain adaptation for fault diagnosis[J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(3): 2296–2305.
- [8] Yu X, Zhao Z, Zhang X, et al. Conditional adversarial domain adaptation with discrimination embedding for locomotive fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1–12.
- [9] Chen Z, He G, Li J, et al. Domain adversarial transfer network for cross-domain fault diagnosis of rotary machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(11): 8702–8712.
- [10] Xiao Y, Shao H, Min Z, et al. Multiscale dilated convolutional subdomain adaptation network with attention for unsupervised fault diagnosis of rotating machinery cross operating conditions[J]. *Measurement*, 2022, 204: 112146.
- [11] Liu Y, Wang Y, Chow T W S, et al. Deep adversarial subdomain adaptation network for intelligent fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(9): 6038–6046.
- [12] 陈超, 郭婧, 屈华伟, 等. 基于多尺度卷积神经网络和 GRU 的轴承故障诊断[J]. *轴承*, 2025(9): 109–119.
Chen Chao, Guo Jing, Qu Huawei, et al. Bearing fault diagnosis based on multi-scale convolutional neural network and GRU[J]. *Bearing*, 2025(9): 109–119.
- [13] Chen Y, Peng G, Zhu Z, et al. A novel deep learning method based on attention mechanism for bearing remaining useful life prediction[J]. *Applied Soft Computing*, 2020, 86: 105919.
- [14] Zhu Y, Zhuang F, Wang J, et al. Deep subdomain adaptation network for image classification[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(4): 1713–1722.
- [15] Qin Y, Wang X, Qian Q, et al. Multiscale transfer voting mechanism: a new strategy for domain adaption[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(10): 7103–7113.
- [16] Wu Z, Jiang H, Liu S, et al. A deep ensemble dense convolutional neural network for rolling bearing fault diagnosis[J]. *Measurement Science and Technology*, 2021, 32(10): 104014.
- [17] Zhao B, Zhang X, Zhan Z, et al. Deep multi-scale convolutional transfer learning network: a novel method for intelligent fault diagnosis of rolling bearings under variable working conditions and domains[J]. *Neurocomputing*, 2020, 407(2): 24–38.
- [18] Zhao Z, Zhang Q, Yu X, et al. Applications of unsupervised deep transfer learning to intelligent fault diagnosis: a survey and comparative study[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70(1): 1–28.
- [19] 宋向金, 孙文举, 刘国海, 等. 深度子领域自适应网络电机滚动轴承跨工况故障诊断[J]. *电工技术学报*, 2024, 39(1): 182–193.
Song Xiangjin, Sun Wenju, Liu Guohai, et al. Across working conditions fault diagnosis for motor rolling bearing based on deep subdomain adaption network[J]. *Transactions of China Electrotechnical Society*, 2024, 39(1): 182–193.
- [20] 孙俊静, 顾幸生. 基于注意力机制多尺度卷积神经网络的轴承故障诊断[J]. *华东理工大学学报(自然科学版)*, 2024, 50(2): 247–256.
Sun Junjing, Gu Xingsheng. Bearing fault diagnosis based on multi-scale convolutional neural network of attention mechanism[J]. *Journal of East China University of Science and Technology*, 2024, 50(2): 247–256.

责任编辑:代小红