

DOI: 10.19595/j.cnki.1000-6753.tces.240574

# 基于角域重采样和特征强化的电机滚动轴承故障迁移诊断方法

王攀攀 李兴宇 张成 韩丽

(中国矿业大学电气工程学院 徐州 221116)

**摘要** 为了降低模型对数据的依赖,实现电机滚动轴承故障从恒转速工况到变转速工况的单源域迁移诊断,提出一种基于角域重采样和特征强化的故障诊断方法。首先,对不同转速工况下的时域振动信号进行角域重采样,降低由转速变化引起的时频分布差异;然后,以协方差损失作为样本特征间的相似性度量,并借助领域对抗网络的思想,扩大不同类别特征间的距离,达到特征强化的目的;最后,利用源域振动数据(恒转速)训练后的卷积神经网络对变转速工况下的故障进行辨识,实现滚动轴承故障的跨转速迁移诊断。实验结果表明,所提方法在完全不涉及目标域数据的情况下,仍能准确地进行故障分类,且其正确率高达97.29%,降低了模型对数据的依赖。

**关键词:** 电机轴承故障 迁移学习 卷积神经网络 角域重采样 特征强化

**中图分类号:** TM307

## 0 引言

在当今工业化和智能制造的时代背景下,电机作为机电设备的关键部件,其健康状况将直接影响生产过程的各个方面。在众多电机故障中,轴承故障的发生概率最高,约占所有故障的43%以上<sup>[1-2]</sup>。因此,准确而及时地诊断电机轴承故障具有重要意义。

振动分析是滚动轴承故障诊断中常用的方法之一<sup>[3]</sup>。通过监测和分析轴承的振动信号,即可判断轴承的运行状态和潜在的故障<sup>[4-5]</sup>。目前,基于振动信号的诊断方法主要包括时域分析法<sup>[6]</sup>、频域分析法<sup>[7]</sup>、时频域分析法<sup>[8]</sup>和人工智能法<sup>[9]</sup>。其中人工智能诊断方法随着深度学习的发展,得到了长足的发展,已成为电机滚动轴承故障诊断领域的研究热点<sup>[10]</sup>。文献[11-13]利用一维卷积神经网络(Convolutional Neural Network, CNN)自动提取振动信号中的故障特征,实现了轴承故障的端到端诊断。文献[14-16]将一维时序信号转换为二维图像,并结合CNN在

图像特征捕捉方面的优势,实现了轴承故障的智能辨识。这类方法虽然能够减少对专家先验知识的依赖,但是要求训练和测试数据具有相同的分布,这在实际应用中往往难以满足<sup>[17-18]</sup>。为此,学者们引入了迁移学习策略,旨在将源域中获得的知识有效迁移到目标域中,从而增强模型在未知条件下的泛化性能<sup>[19]</sup>。文献[20]利用迁移成分分析法将不同工况下的特征集向参考工况做迁移映射,从而降低工况变化对域特征的影响,实现了变工况下的轴承故障识别。文献[21]通过领域对抗学习策略,缩小了源域与目标域间的数据分布差异,使模型在面对不同转速工况时能够准确识别轴承故障。文献[22]提出多尺度子领域自适应方法,通过局部最大均值差异完成领域适配,达到降低域间特征差异的目的,从而提高模型的泛化性。上述领域自适应方法实现了不同工况间的迁移诊断,但是该类方法在网络训练过程中需要足够多的目标域无标签样本(健康和故障数据),这在工程实际中仍然较难满足。

文献[23]在多个已知源域间通过领域对抗学习策略,提取出域间的共同特征,以实现目标域的故障分类。文献[24]提出了一种基于类边界特征检测的对抗性领域泛化网络,通过对抗训练从一个有标签源域和多个无标签辅助域中获得域不变特征,实

现了未知环境下的故障诊断。文献[25]将多个不同规格和工况的已知标签数据作为源域,采用改进异构模型参数的迁移策略,将源域知识迁移到目标域模型,并利用目标域少量带标签数据对分类器进行微调,取得了较好的迁移识别效果。上述领域泛化方法利用多个源域数据构建网络模型,使其能够在目标域数据上也有较好的表现。但是这类方法在网络训练过程中仍需要多个源域数据,对数据的依赖性仍较大。

鉴于此,为了降低模型对数据的依赖性,本文从降低域间数据时频差异和提升模型泛化性能的角度出发,提出一种基于角域重采样(Angular Domain Resampling, ADR)和特征强化的电机滚动轴承故障迁移诊断方法,以期在完全不涉及目标域数据的情况下,实现从恒转速工况到变转速工况的单源域迁移诊断。

## 1 相关理论

### 1.1 角域重采样

角域重采样(ADR)是一种在非稳态信号分析中常用的方法,它通过等角度采样将时域中的非稳态信号转变为角域里的伪稳态信号<sup>[26]</sup>。

首先,对获取的转速瞬时频率 $f_i(t)$ 进行积分运算,求得累积角度为

$$\theta(t) = \int_0^t f_i(t) dt \quad (1)$$

式中, $\theta(t)$ 为转轴从开始旋转到 $t$ 时转过的总角度。

其次,设定角域重采样的等角度采样间隔 $\Delta\theta = 2\pi/N$ ,其中 $N$ 为转轴每圈的采样点数,则每个特定角度所对应的时间点 $t_n$ 可定义为

$$t_n = \theta^{-1}(n\Delta\theta) \quad (2)$$

式中, $n$ 为采样点序号; $\theta^{-1}$ 为 $\theta(t)$ 的逆函数,用于从角度值反推时间点。

最后,利用计算出的时间点,通过插值法将原始时域信号转换为等角度采样信号,为后续分析提供频率上相对稳定的角域信号。

### 1.2 深度学习中的特征强化

在深度学习中,特征强化指的是通过一些方法改进模型对输入数据特征的识别和利用能力,增强数据中的关键特征并抑制无关或冗余信息,以提高模型的准确性和鲁棒性。在CNN中,通常通过设计特定的网络结构和特殊的损失函数等手段实现特征强化策略。

CNN能够自动地从大量数据中学习复杂的特征表示,通过层次化的结构,实现从简单的边缘和形状特征中逐渐提炼出高级的抽象特征。在这个过程中,特征的强化可以通过设计相应的网络结构或训练策略来实现。例如,通过集成注意力机制,训练网络识别并关注数据中对完成特定任务最关键的部分,从而对这些重要特征进行强化。此外,通过定制的损失函数,还可以进一步引导模型在训练期间优先关注和强化对于最终任务最有贡献的特征,从而在分类或回归任务中达到更优的性能。本文基于后者实现对网络提取特征的强化。

## 2 融合特征强化策略的CNN网络

在故障诊断的分类任务中,模型的泛化能力是衡量其性能的关键指标。一般的故障分类CNN网络主要包括两部分:特征提取网络和故障分类网络。特征提取网络用于从原始信号中提取关键特征;而故障分类网络则利用这些提取的特征完成故障分类。受领域对抗神经网络的启发,本节对故障分类CNN进行改进:①特征提取网络采用残差神经网络(Residual Network, ResNet)<sup>[27]</sup>;②对所提取的特征进行协方差损失计算,并结合梯度翻转层(Gradient Reversal Layer, GRL)对特征提取网络参数进行调整,不断增大协方差损失,以期扩大特征向量间的差异性,达到特征强化的目的,使得网络模型具有更强的泛化性。改进后的网络模型结构和梯度更新过程如图1所示。

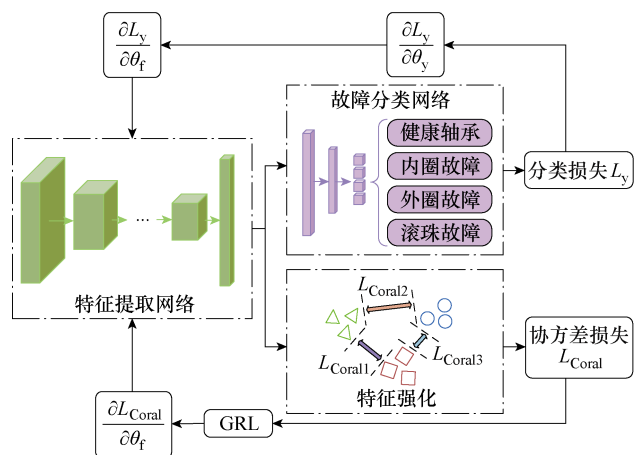


图1 融合特征强化策略的故障分类神经网络及梯度更新过程

Fig.1 Fault classification neural network and gradient update process based on fusion feature enhancement strategy

## 2.1 特征提取网络与故障分类网络

图 1 中的特征提取网络主要由 ResNet 构成,其核心在于引入了残差连接,这不仅有效地解决了网络加深导致的退化问题,而且通过融合不同尺度的感受野特征,使得网络的每个神经元能获取更为丰富的信息。因此,本文的特征提取网络借鉴了 ResNet 架构,其基础残差块结构如图 2 所示。




图 2 基础残差块结构

Fig.2 Basic residual block structure

故障分类网络的主要目的是建立特征与样本标签之间的非线性映射关系。在 CNN 网络中,通常以全连接层的方式实现。分类网络往往采用交叉熵作为损失函数,其样本  $i$  的分类损失定义为

$$L_{yi}(\theta_f, \theta_y) = L_y(G_y(G_f(x_i; \theta_f); \theta_y), y_i) = \sum_{k=1}^M y_i^{(k)} \lg \frac{1}{G_y^{(k)}(G_f(x_i; \theta_f); \theta_y)} \quad (3)$$

式中,  $G_f(\cdot)$  为特征提取网络的输出函数;  $G_y(\cdot)$  为故障分类网络的输出函数;  $x_i$  为样本  $i$  的输入;  $\theta_f$  为特征提取网络的参数;  $\theta_y$  为故障分类网络的参数;  $y_i$  为样本真实标签的独热编码;  $M$  为分类的数量。

## 2.2 特征强化策略

本节提出一种特征强化学习策略,旨在提升单源域数据下深度学习模型分类泛化能力。这一策略的核心是在训练过程中对不同类别的特征进行相似性分析,并借助领域对抗网络的思想扩大不同类别特征间的距离,从而增强不同类别的特征差异性来优化模型性能。整个过程类似于在高维特征空间内扩大不同类别特征间的距离,特征强化过程示意图如图 3 所示。




图 3 特征强化过程示意图

Fig.3 Feature enhancement process schematic

由于协方差能够较全面地捕捉特征间的相关性,因此,本文引入协方差损失来度量不同特征间的相似性。

对于任意一个样本的特征向量  $D_k$ ,其协方差矩阵  $C_k$  定义为

$$C_k = \frac{1}{n_k - 1} \left[ D_k^T D_k - \frac{1}{n_k} (\mathbf{1}^T D_k)^T (\mathbf{1}^T D_k) \right] \quad (4)$$

式中,“ $\mathbf{1}$ ”为单位列向量;  $n_k$  为特征数量。

任意两个样本特征的相似度可以通过计算两者协方差矩阵差值的 Frobenius 范数获得,即协方差损失  $L_{Coral}$ ,具体形式为

$$L_{Coral} = \frac{1}{4d^2} \|C_p - C_q\|_F^2 \quad (5)$$

式中,  $C_p$  和  $C_q$  分别为第  $p$  个和第  $q$  个样本特征的协方差矩阵;  $d$  为样本特征的维数;  $\|\cdot\|_F^2$  为 Frobenius 范数。

为了扩大不同类别特征间的距离,在网络训练过程中,先将协方差总损失通过 GRL 实现梯度反转;然后进行网络损失的反向传播,调整特征提取网络的权值,实现不同类别特征的强化。这一过程通过不断的迭代迫使网络挖掘出区分性更高的故障特征,使模型对不同的故障类别具有更强的辨识力。

## 2.3 融合特征强化策略的神经网络具体实现

结合 2.1 节和 2.2 节可以得出,网络的总损失由分类损失和协方差损失加权组成,即

$$L_{sum}(\theta_f, \theta_y) = \sum (L_{yi}(\theta_f, \theta_y) - \lambda L_{Coral_j}(\theta_f)) = \frac{1}{n_s} \sum_{i=1}^{n_s} L_{yi}(\theta_f, \theta_y) - \lambda \frac{1}{w} \sum_{j=1}^w L_{Coral_j}(\theta_f) \quad (6)$$

式中,  $n_s$  为源域样本数量;  $w$  为训练样本集的组合数,  $w = C_M^2$ ;  $\lambda$  为协方差损失的权重。网络训练过程中的优化目标为最小化分类网络损失和最大化协方差损失。网络的优化目标函数为

$$(\hat{\theta}_f, \hat{\theta}_y) = \arg \min_{\theta_f, \theta_y} L_{sum}(\theta_f, \theta_y) \quad (7)$$

综上所述,融合特征强化策略的 CNN 网络的具体实现步骤为:

(1) 将源域数据样本输入特征提取网络,得到其数据样本的特征向量。

(2) 将获取的特征向量输入故障分类网络, 根据式(3), 计算分类损失, 并将该损失反向传播, 调整故障分类网络的权重参数。

(3) 依据式(4), 计算步骤(1)中所获取每个特征向量的协方差矩阵。

(4) 根据式(5), 对任意两个不同标签的协方差矩阵进行比较, 计算它们之间的协方差损失。

(5) 将所得的协方差损失进行累加, 求得整体协方差损失, 并通过 GRL 实现梯度反转。

(6) 依据式(6)计算网络的总损失, 并将总损失进行反向传播, 调整特征提取网络的权重参数。

### 3 基于角域重采样和特征强化的电机滚动轴承故障诊断方法

当滚动轴承发生某种故障(内圈、外圈或滚珠故障)时, 无论是在恒速还是变速情况下都将产生周期性的冲击振动。这个周期性的冲击振动就是源

域(恒速)和目标域(变速)间的“相似性”, 可用于跨域迁移诊断; 但是该冲击性振动的频率会随着转速的变化而变化, 致使两域间的数据分布差异仍然较大, 难以实现高精度的故障迁移识别。因此, 本节先利用角域重采样技术, 将振动信号从时域转换至角域, 保证不同转速下的振动信号具有相同的振动冲击间隔, 进而降低由转速变化引起的域间数据分布差异。

振动幅值的差异也是引起数据分布差异的另一个重要因素, 也将直接影响迁移识别的效果。为此, 本节通过第2节特征强化的方法, 改善整个故障识别网络模型在目标域的泛化性能, 进而降低振动幅值差异对迁移诊断效果的影响。

综上所述, 为了实现电机滚动轴承从恒转速工况到变转速工况的单源域迁移诊断, 将角域重采样与特征强化相结合, 提出一种电机滚动轴承故障诊断方法。具体如图4所示。

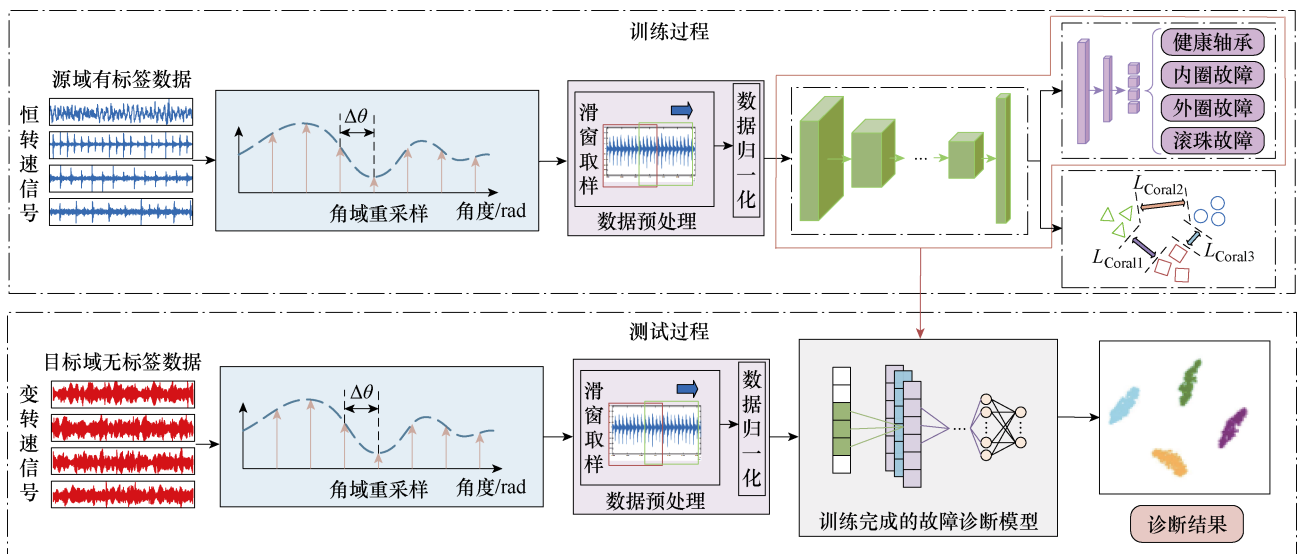


图4 基于角域重采样和特征强化的电机滚动轴承故障诊断方法

Fig.4 Fault diagnosis method for motor rolling bearing based on angular domain resampling and feature enhancement

首先对不同工况下的时域振动信号进行角域重采样, 以期减小由转速变化引起的时频特性差异; 然后利用恒转速工况下的振动信号训练分类网络, 并借助特征强化学习策略迫使网络提取出更有价值的故障信息, 以增强网络模型的泛化性能; 最后将训练后的网络模型直接用于变转速工况下的电机轴承故障识别, 实现电机滚动轴承故障在不同转速工况间的单源域迁移诊断。具体实施步骤如下:

(1) 采集电机在恒转速工况下的振动信号和转速信号, 并按照 1.1 节方法对原信号进行角域重采样。

(2) 将恒转速工况下的角域振动信号进行滑窗取样(细节可参考第4节实验部分), 增加数据样本数量。

(3) 对数据样本进行归一化处理(均值为0, 标准差为1), 形成源域有标签数据集; 同时, 将该数据集按比例划分为训练集和测试集。

(4) 利用步骤(3)的数据集对文中第2节的神经网络进行训练, 实现源域数据的特征提取、特征强化和故障分类。

(5) 采集变转速工况下的振动信号, 按照 1.1 节方法对其进行角域重采样, 且在重采样过程中,

采样间隔 $\Delta\theta$ 须与恒转速工况保持一致。

(6) 对变转速下的重采样信号进行滑窗取样, 并进行归一化处理, 形成目标域无标签数据集。

(7) 将目标域数据样本直接输入步骤(4)中已经训练完成的网络模型中, 进行故障分类, 实现电机滚动轴承的跨转速工况的迁移诊断。

#### 4 实验验证与分析

为验证所提方法的有效性, 设计了如图 5 所示的实验平台。实验电机为 YXVF-90S-4 三相感应电动机; 负载为 CZF-1.2 型磁粉制动器; 变频器型号为汇川 MD380; PLC 型号为 SIMATIC S7-1200 (用于实现电机的加减速控制); 转速编码器型号为 E80H20-1024-3-N-24; 振动传感器型号为 CA-YD-186, 垂直安装于电机驱动端的轴承端盖; 采集卡型号为 Smacq-USB-4621。




图 5 滚动轴承故障检测实验平台

Fig.5 Rolling bearing fault detection experimental platform

为模拟轴承故障, 定制了内圈、外圈和滚珠的划痕贯穿故障轴承, 具体如图 6 所示。划痕尺寸为  $0.2\text{ mm}\times 0.5\text{ mm}$  (宽度 $\times$ 深度)。




图 6 故障轴承实物图

Fig.6 Actual image of the faulty bearing

##### 4.1 构建数据集

实验包含轴承四类健康状况, 分别为健康轴承、内圈故障、外圈故障和滚珠故障。采用变频器驱动电机, 以实现电机的转速变化。对各健康状况轴承分别进行恒转速 (50 Hz) 和变转速 (40 Hz $\rightarrow$ 20 Hz $\rightarrow$ 50 Hz) 不同工况下的满载运行实验。采集电机驱动端垂直振动信号, 采样时长为 13 s, 采样频率为

48 kHz, 一共得到八组数据。

对采集到的时域振动信号进行角域重采样, 得到角域振动数据。然后对重采样后的数据进行滑窗取样, 生成数据集, 各数据集样本数量见表 1, 其中数据窗长度为 2 048, 滑动步长为 512。

表 1 各数据集样本数量

Tab.1 Sample quantities for each dataset

健康状态	所属领域		
	源域 (恒转速)		目标域 (变转速)
	训练集	测试集	测试集
健康轴承	1 000	200	1 000
内圈故障	1 000	200	1 000
外圈故障	1 000	200	1 000
滚珠故障	1 000	200	1 000

##### 4.2 构建网络模型

本实验中的卷积神经网络采用 Pytorch 深度学习框架实现, 其具体的结构参数见表 2。

表 2 网络结构参数

Tab.2 Network structure parameters

网络	网络层类型	核尺寸/步长	核数量	输出数据长度
特征提取网络	Conv1D	7 $\times$ 1/2 $\times$ 1	64	1 $\times$ 1 024
	Maxpooling	3 $\times$ 1/2 $\times$ 1	64	1 $\times$ 512
	RB $\times$ 2	5 $\times$ 1/1 $\times$ 1	64	1 $\times$ 512
	Maxpooling	3 $\times$ 1/2 $\times$ 1	64	1 $\times$ 256
	RB $\times$ 2	5 $\times$ 1/2 $\times$ 1	128	1 $\times$ 64
	Maxpooling	3 $\times$ 1/2 $\times$ 1	128	1 $\times$ 32
	RB $\times$ 2	5 $\times$ 1/1 $\times$ 1	256	1 $\times$ 32
	Maxpooling	3 $\times$ 1/2 $\times$ 1	256	1 $\times$ 16
	RB $\times$ 2	5 $\times$ 1/2 $\times$ 1	512	1 $\times$ 4
	Averagepooling	4 $\times$ 1	512	512
分类网络	FC	—	—	256
	Dropout	—	—	256
	FC	—	—	4
	Softmax	—	—	4

训练过程使用 Adam 算法优化参数, 协方差损失的权重 $\lambda$ 设为 0.01, 学习率设置为 0.001, 训练迭代次数为 200, 批大小设置为 200。

##### 4.3 角域重采样技术有效性验证

为验证角域重采样技术对振动信号时频特性的影响, 本节以实测电机轴承内圈故障的变转速振动信号为例, 对比角域重采样前后振动信号的时频特性, 具体如图 7 所示。

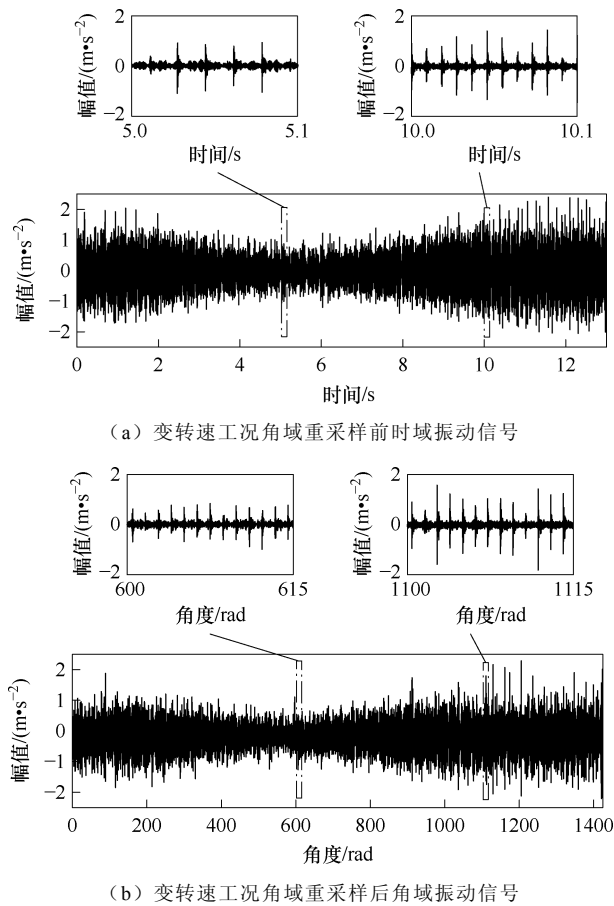


图7 变转速工况振动信号角域重采样前后对比

Fig.7 Comparison of vibration signals in variable speed conditions before and after angular domain resampling

从图7a可以观察到,在角域重采样之前,由于转速的变化,振动信号在时域上表现出不同的冲击频率,即:转速较低时,冲击间隔较大;转速较高时,冲击间隔较小,冲击频率与转速呈正相关。然而,在图7b中,角域重采样后的振动信号无论是在低转速下还是在高转速下,振动的冲击间隔几乎是一样的,有效地降低了振动数据在时频特性上的分布差异。

#### 4.4 特征强化有效性验证

为验证特征强化过程的有效性,本节通过t-分布随机邻居嵌入(t-Distributed Stochastic Neighbor Embedding, t-SNE)降维可视化技术对比分析了训练过程中特征强化前后,训练数据特征在空间中的分布情况,具体如图8所示。在网络训练至20轮时,不同类别间的特征分类已变得较为明显,此时训练集正确率已经达到较为理想的状态。在未加入特征强化学习策略的网络中,网络权重的更新较为缓慢,训练20轮和训练30轮的特征分布无明显差异,表明整个网络的学习过程基本结束,特征提取网络已

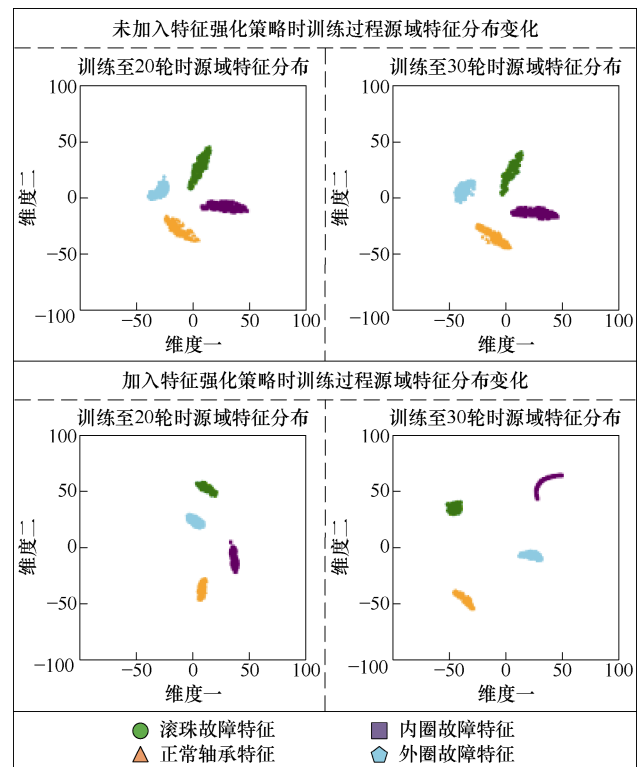


图8 特征强化前后训练数据特征空间分布对比

Fig.8 Comparison of feature space distribution in training data before and after feature enhancement

难以进一步挖掘出新的特征,各种故障的特征区分度已达到瓶颈。这种现象反映了传统训练方式中,网络依赖已有的特征差异,而忽略了进一步挖掘潜在重要特征的能力。相比之下,由于协方差损失的引入,特征强化网络在训练过程中不断地寻找差异性更大的特征。经过30轮训练后,可以清晰地观察到特征空间分布的差异性显著增加,说明协方差损失对于提升特征区分度起到了关键作用,促使网络更好地学习到更具区分性的特征。

#### 4.5 实验结果分析

将恒转速工况下的振动数据作为源域,变转速工况下的振动数据作为目标域。利用源域数据训练网络模型,并直接在目标域数据上进行测试。为了对比分析,本文还将其他四种方法应用于该实验。

方法I:不使用角域重采样技术和特征强化学习策略,仅利用图1中的特征提取网络与故障分类网络对恒转速振动数据进行学习,并直接对变转速振动数据进行测试。

方法II:在不进行角域重采样的情况下,利用图1中的整个网络对恒转速振动数据进行学习,并直接对变转速振动数据进行测试。

方法III:在对振动信号进行角域重采样的基础

上, 仅利用图 1 中的特征提取网络和故障分类网络对恒转速振动数据进行学习, 并直接对变速振动数据进行测试。

方法IV: 在对振动数据进行角域重采样的基础上, 通过最大均值差异(Maximum Mean Discrepancy, MMD) 核来衡量特征间的差异性, 并结合 GRL 实现特征强化; 利用恒速振动数据进行网络训练, 最后对变速振动数据进行测试。

为更好地评估网络模型的分类准确度, 对目标域数据集引入正确率、召回率、F1-分数三种表征参数。由于本文验证集中各类数据量一致, 此处召回率设定为正常和故障(内圈故障、外圈故障、滚珠故障)之间分类的召回率, F1-分数为正确率和上述召回率的调和平均数, 10 次实验平均结果见表 3。

表 3 各迁移方法实验结果

Tab.3 Experimental results for various transfer method

迁移方法	正确率	召回率	F1-分数
方法 I	58.38	75.82	65.32
方法 II	62.25	77.04	68.47
方法 III	89.84	92.86	90.76
方法 IV	91.17	93.61	91.95
所提方法	97.29	97.65	97.33

从实验结果可以看出, 所提方法的正确率、召回率以及 F1-分数均优于对比方法, 为了进一步研究模型的性能, 绘制了各方法目标域测试集识别结果的混淆矩阵, 如图 9 所示。

由表 3 和图 9 可以看出, 方法 I 由于未采用角域重采样技术和特征强化学习策略, 其故障分类效果最差, 识别正确率仅为 58.38%, 且滚珠和内圈故障的识别率不到 50%; 这主要是由于转速的不同导致源域和目标域间的数据分布差异过大, 难以成功实现知识的迁移。相比之下, 方法 II 采用了特征强化学习策略, 其故障识别率有所提升, 达到了 62.25%; 但由于未使用角域重采样技术, 网络模型无法适应转速变化引起的特征分布偏移, 导致分类效果仍然不理想, 未能将滚珠故障和健康轴承区分开。在方法 III 中, 由于采用了角域重采样技术, 故障识别率显著提升, 达到了 89.84%, 特别是滚珠故障和健康轴承的区分性较好, 这表明角域重采样技术对于减小由转速变化引起的时频特性偏移至关重要; 但是由于没有采用特征强化学习策略, 网络模型无法减弱振动幅值对故障迁移识别的影响, 导致

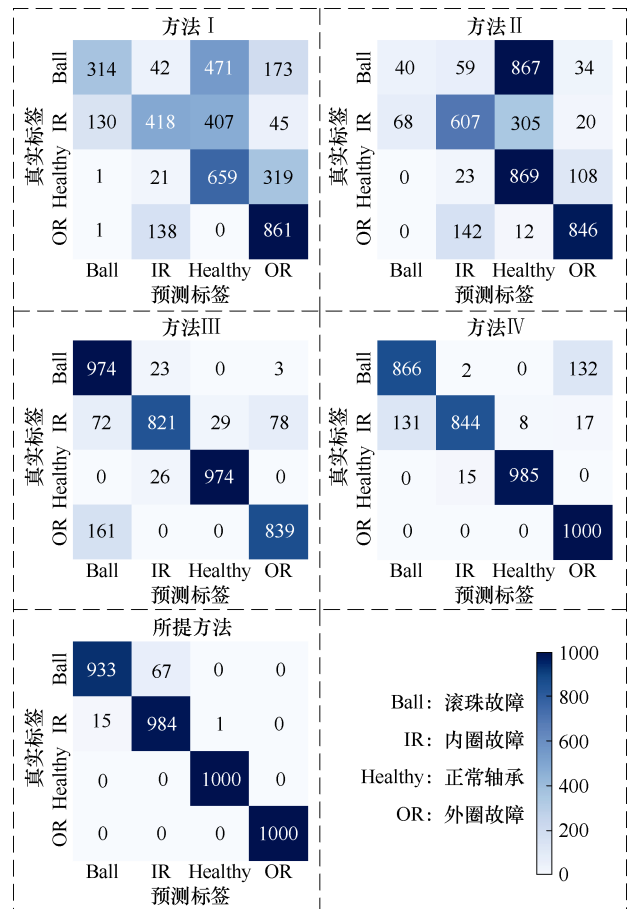


图 9 目标域测试集识别结果混淆矩阵

Fig.9 Confusion matrix of identification results on the target domain test set

识别精度得不到进一步提升。方法 IV 在使用角域重采样技术的同时, 通过 MMD 度量特征差异, 完成了特征强化过程, 其故障识别率达到了 91.17%; 但 MMD 方法主要关注均值差异, 在处理复杂的特征关系时表现出一定的局限性, 特别是对于内圈和滚珠故障的振动信号, 由于其特征频率接近, 特征间的均值差异性有限, 从而影响了该方法的故障识别正确率。相较之下, 本文所提方法结合了角域重采样技术和协方差度量的特征强化方法, 其故障识别正确率、召回率以及 F1-分数均表现出色, 分别达到了 97.29%、97.65%和 97.33%。这一成效主要得益于两方面, 一方面通过角域重采样技术大大降低了源域和目标域间的数据分布差异, 为实现高精度迁移识别奠定了基础; 另一方面, 基于协方差度量的特征强化策略能迫使网络提取出故障信息含量更高的特征, 增强了对关键特征的表达, 从而显著提升了网络模型的泛化性能, 降低了域间振动信号幅值的差异对故障迁移识别的影响。

#### 4.6 不同负载工况对识别精度的影响分析

为验证所提方法在不同负载工况下的鲁棒性, 本节设计了六种不同负载工况下的迁移诊断任务, 具体迁移任务见表 4。

表 4 不同负载工况下迁移诊断任务

Tab.4 Transfer diagnosis tasks under different load conditions

迁移任务	领域设置	
	源域 (50 Hz)	目标域 (变转速)
1	空载	半载
2	空载	满载
3	半载	空载
4	半载	满载
5	满载	空载
6	满载	半载

针对每个迁移任务进行 10 次独立实验, 并对各项指标 (包括正确率、召回率和 F1-分数) 取其平均值, 实验结果汇总如图 10 所示。

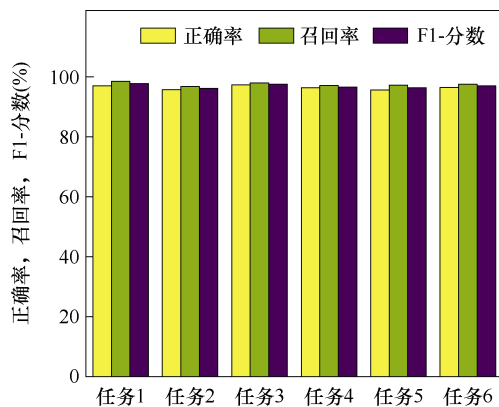


图 10 变负载迁移任务下结果

Fig.10 Results under variable load transfer tasks

从图 10 结果可见, 在所有的迁移任务中, 所提方法均展现出较高的正确率 ( $\geq 95.72\%$ )、召回率 ( $\geq 96.77\%$ ), 以及 F1-分数 ( $\geq 96.19\%$ ); 这充分说明了所提方法能有效地适应负载变化带来的数据分布差异, 在应对不同负载变化时具备较好的鲁棒性。

#### 4.7 样本数量对故障识别精度的影响分析

为了分析样本数量对所提方法的影响, 本节将每一类源域样本数据量在 10~1 000 范围内进行变化, 测试所提方法的迁移识别准确率, 其结果如图 11 所示。图中横坐标表示每个类别的样本数量, 纵坐标为目标域测试的正确率。

从图 11 中可以看出, 随着样本数量从 10 增加




图 11 样本数量变化对训练结果影响

Fig.11 Effect of sample size variation on training results

到 100, 模型的正确率显著提升; 在数据量超过 100 后, 正确率的增长趋于缓慢, 特别是当样本数量大于 500 后, 正确率的增长更加缓慢; 但是在该数据量下所提方法的正确率都在 95% 以上, 达到了较好的识别效果。因此, 建议在模型训练中确保每类样本数至少为 500。

#### 4.8 不同转速工况对故障识别精度的影响分析

为验证不同转速工况下的模型泛化性, 本节设计了多个不同转速间的迁移诊断任务, 具体见表 5。表 5 中 30、40、50 Hz 为恒定转速工况, 变转速的定义与 4.1 节一致。

表 5 多种变速工况下迁移诊断正确率

Tab.5 Transfer diagnostic accuracy in multiple variable speed conditions

	目标域			
	30 Hz	40 Hz	50 Hz	变转速
源域	30 Hz	99.35	98.55	96.04
	40 Hz	97.95	99.98	95.29
	50 Hz	97.13	99.18	97.29
	变转速	99.85	99.95	99.98

从表 5 可以看出, 各迁移任务在不同转速条件下的诊断效果皆较为理想。其中, 源域为变转速、目标域为恒转速的任务, 由于在训练过程中已涵盖各种恒转速工况的特征信息, 因此迁移诊断效果更好, 故障识别率都保持在 99.85% 以上。相比之下, 源域为恒转速、目标域为变转速的任务, 由于模型只学习了某一恒转速工况下的特征信息, 因此迁移识别难度更大, 其识别正确率有所下降, 但仍能保持在 95% 以上。

## 5 结论

本文在 CNN 网络的基础上, 结合角域重采样技术和特征强化策略, 提出了一种能够从恒转速工况迁移到变转速工况的滚动轴承故障诊断方法, 并得出以下结论:

1) 所提方法通过角域重采样技术, 有效地降低了源域和目标域数据中因转速变化而导致的分布差异, 为跨转速工况的迁移诊断降低了难度。

2) 所提方法利用协方差损失度量不同特征间的相似性, 并借助领域对抗网络的思想扩大了不同类别特征之间的距离, 提升了网络模型对故障辨识的泛化性能。

3) 所提方法在完全不涉及目标域数据的情况下, 仍能在多种变速工况下的迁移诊断任务中准确辨识电机滚动轴承的各种故障, 且对负载变化具有较好的鲁棒性。

需要指出的是, 当前研究主要集中在单一类型故障的诊断, 对于复合故障或分布式故障的迁移诊断尚未深入探讨。因此, 未来工作将致力于扩展模型以处理更复杂的故障类型, 进一步提升方法在实际工业应用中的适用性和鲁棒性。

### 参考文献

- [1] 迟连强, 张殿海, 赵俊清, 等. 旋转电机轴承电蚀损伤机理与缓解措施研究进展[J]. 电工技术学报, 2024, 39(20): 6409-6430.  
Chi Lianqiang, Zhang Dianhai, Zhao Junqing, et al. Research progress on the mechanism and mitigation measure of electrical corrosion damage in rotating motor bearings[J]. Transactions of China Electrotechnical Society, 2024, 39(20): 6409-6430.
- [2] 宋向金, 赵文祥. 交流电机信号特征分析的滚动轴承故障诊断方法综述[J]. 中国电机工程学报, 2022, 42(4): 1582-1595.  
Song Xiangjin, Zhao Wenxiang. A review of rolling bearing fault diagnosis approaches using AC motor signature analysis[J]. Proceedings of the CSEE, 2022, 42(4): 1582-1595.
- [3] 党永亮, 张玉焜, 祝令瑜, 等. 基于麦克斯韦力-振动耦合的高压油浸式并联电抗器铁心多倍频振动机理研究[J]. 电工技术学报, 2024, 39(增刊 1): 117-126.  
Dang Yongliang, Zhang Yukun, Zhu Lingyu, et al. Study on multi-harmonic vibration mechanism of high-voltage shunt reactor core based on coupling between Maxwell force and vibration[J]. Transactions of China Electrotechnical Society, 2024, 39(S1): 117-126.
- [4] 郑毅, 王承民, 刘保良, 等. 基于多层级时空图神经网络的风电机组在线异常检测[J]. 电力系统自动化, 2024, 48(5): 107-119.  
Zheng Yi, Wang Chengmin, Liu Baoliang, et al. Online anomaly detection of wind turbines based on hierarchical spatio-temporal graph neural network[J]. Automation of Electric Power Systems, 2024, 48(5): 107-119.
- [5] Jahagirdar A C, Gupta K K. Cumulative distribution sharpness profiling based bearing fault diagnosis framework under variable speed conditions[J]. IEEE Sensors Journal, 2021, 21(13): 15124-15132.
- [6] 唐贵基, 邓飞跃, 张超, 等. 基于倒谱预白化和奇异值分解的滚动轴承故障特征提取方法[J]. 中国电机工程学报, 2014, 34(35): 6355-6361.  
Tang Guiji, Deng Feiyue, Zhang Chao, et al. Extraction method of rolling bearing fault feature based on cepstrum pre-whitening and singular value decomposition[J]. Proceedings of the CSEE, 2014, 34(35): 6355-6361.
- [7] Wang Teng, Liu Zheng, Lu Guoliang, et al. Temporal-spatio graph based spectrum analysis for bearing fault detection and diagnosis[J]. IEEE Transactions on Industrial Electronics, 2021, 68(3): 2598-2607.
- [8] 赵一楠, 刻昌锋, 孟佳东, 等. 自适应窗口旋转优化短时傅里叶变换的变转速滚动轴承故障诊断[J]. 振动工程学报, 2024, 37(6): 1064-1076.  
Zhao Yinan, Yan Changfeng, Meng Jiadong, et al. Fault diagnosis of rolling bearings under variable speed conditions based on adaptive window rotation optimization short-time Fourier transform[J]. Journal of Vibration Engineering, 2024, 37(6): 1064-1076.
- [9] 卞文彬, 邓艾东, 刘东川, 等. 基于改进深度残差收缩网络的风电机组滚动轴承故障诊断方法[J]. 机械工程学报, 2023, 59(12): 202-214.  
Bian Wenbin, Deng Aidong, Liu Dongchuan, et al. Fault diagnosis method of wind turbine rolling bearing based on improved deep residual shrinkage network[J]. Journal of Mechanical Engineering, 2023,

- 59(12): 202-214.
- [10] Chen Xiaohan, Yang Rui, Xue Yihao, et al. Deep transfer learning for bearing fault diagnosis: a systematic review since 2016[J]. *IEEE Transactions on Instrumentation and Measurement*, 2016, 72: 3508221.
- [11] 杨洁, 万安平, 王景霖, 等. 基于多传感器融合卷积神经网络的航空发动机轴承故障诊断[J]. *中国电机工程学报*, 2022, 42(13): 4933-4942.  
Yang Jie, Wan Anping, Wang Jinglin, et al. Aeroengine bearing fault diagnosis based on convolutional neural network for multi-sensor information fusion[J]. *Proceedings of the CSEE*, 2022, 42(13): 4933-4942.
- [12] 郑一珍, 牛藺楷, 熊晓燕, 等. 基于一维卷积神经网络的圆柱滚子轴承保持架故障诊断[J]. *振动与冲击*, 2021, 40(19): 230-238, 285.  
Zheng Yizhen, Niu Linkai, Xiong Xiaoyan, et al. Fault diagnosis of cylindrical roller bearing cage based on 1D convolution neural network[J]. *Journal of Vibration and Shock*, 2021, 40(19): 230-238, 285.
- [13] 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 Wenfeng, Chen Hui, Zhang Meiling, 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.
- [14] 张辉, 戈宝军, 韩斌, 等. 基于 GAF-CapsNet 的电机轴承故障诊断方法[J]. *电工技术学报*, 2023, 38(10): 2675-2685.  
Zhang Hui, Ge Baojun, Han Bin, et al. Fault diagnosis method of motor bearing based on GAF-CapsNet[J]. *Transactions of China Electrotechnical Society*, 2023, 38(10): 2675-2685.
- [15] 宁方立, 王珂, 郝明阳. 融合 CNN 和 ViT 的声信号轴承故障诊断方法[J]. *振动与冲击*, 2024, 43(3): 158-163, 170.  
Ning Fangli, Wang Ke, Hao Mingyang. Fault diagnosis method for bearing based on fusing CNN and ViT[J]. *Journal of Vibration and Shock*, 2024, 43(3): 158-163, 170.
- [16] 全钰, 庞新宇, 魏子涵. 基于 GADF-CNN 的滚动轴承故障诊断方法[J]. *振动与冲击*, 2021, 40(5): 247-253, 260.  
Tong Yu, Pang Xinyu, Wei Zihan. Fault diagnosis method of rolling bearing based on GADF-CNN[J]. *Journal of Vibration and Shock*, 2021, 40(5): 247-253, 260.
- [17] Yang Bin, Xu Songci, Lei Yaguo, et al. Multi-source transfer learning network to complement knowledge for intelligent diagnosis of machines with unseen faults[J]. *Mechanical Systems and Signal Processing*, 2022, 162: 108095.
- [18] Xiao Dengyu, Huang Yixiang, Zhao Lujie, et al. Domain adaptive motor fault diagnosis using deep transfer learning[J]. *IEEE Access*, 2019, 7: 80937-80949.
- [19] 金亮, 闫银刚, 杨庆新, 等. 小样本条件下永磁同步电机深度迁移学习性能预测方法[J]. *电工技术学报*, 2023, 38(18): 4921-4931.  
Jin Liang, Yan Yingang, Yang Qingxin, et al. Prediction method of deep transfer learning performance of permanent magnet synchronous motor under the condition of few-shot[J]. *Transactions of China Electrotechnical Society*, 2023, 38(18): 4921-4931.
- [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 Honglin, Bo Lin, Hou Dongming, 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] Tian Jing, Wang Dong, Chen Liang, et al. A stable adaptive adversarial network with exponential adversarial strategy for bearing fault diagnosis[J]. *IEEE Sensors Journal*, 2022, 22(10): 9754-9762.
- [22] 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.
- [23] Chen Liang, Li Qi, Shen Changqing, et al. Adversarial domain-invariant generalization: a generic domain-regressive framework for bearing fault diagnosis under unseen conditions[J]. IEEE Transactions on Industrial Informatics, 2022, 18(3): 1790-1800.
- [24] Li Jingde, Shen Changqing, Kong Lin, et al. A new adversarial domain generalization network based on class boundary feature detection for bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 2506909.
- [25] 王玉静, 夏林, 康守强, 等. 基于多源域异构模型迁移的滚动轴承故障诊断方法[J]. 振动与冲击, 2023, 42(24): 257-266.
- Wang Yujing, Xia Lin, Kang Shouqiang, et al. A fault diagnosis method of rolling bearings based on multi-source domain heterogeneous model transfer[J]. Journal of Vibration and Shock, 2023, 42(24): 257-266.
- [26] Lu Siliang, Guo Jie, He Qingbo, et al. A novel contactless angular resampling method for motor bearing fault diagnosis under variable speed[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(11): 2538-2550.
- [27] 褚旭, 鲍泽宏, 许立强, 等. 基于时序卷积残差网络的主动配电系统线路短路故障诊断方案[J]. 电工技术学报, 2023, 38(8): 2178-2190.
- Chu Xu, Bao Zehong, Xu Liqiang, et al. Fault line diagnosis scheme of active distribution system based on time-sequence convolution residual network[J]. Transactions of China Electrotechnical Society, 2023, 38(8): 2178-2190.

#### 作者简介

王攀攀 男, 1982 年生, 副教授, 硕士生导师, 研究方向为电气设备故障诊断、新能源发电技术和工业自动化。

E-mail: wpp2011@126.com (通信作者)

李兴宇 男, 1999 年生, 硕士研究生, 研究方向为电气设备故障诊断。

E-mail: 17863928786@163.com

## Fault Transfer Diagnosis Method for Motor Rolling Bearings Based on Angular Domain Resampling and Feature Enhancement

Wang Panpan Li Xingyu Zhang Cheng Han Li

(School of Electrical Engineering China University of Mining and Technology Xuzhou 221116 China)

**Abstract** As the demand for flexibility and efficiency in modern industrial equipment increases, motors often operate under variable speed conditions in real-world industrial applications. This poses challenges for traditional time-domain and frequency-domain fault diagnosis methods. These challenges arise primarily due to the non-linear and non-stationary characteristics of signals under variable speed conditions, which can affect fault feature extraction. Single deep learning models generally require training and test data to follow the same distribution, and domain adaptation or multi-source domain generalization methods are difficult to apply in the absence of target domain and multi-source domain data, limiting their ability to enhance the generalization of single-source domain models. To address these challenges, this study proposes a motor rolling bearing fault transfer diagnosis method that integrates angular domain resampling and feature enhancement.

First, to mitigate the issue of time-frequency characteristic offsets in vibration signals under different rotational speeds, angular domain resampling is employed. This technique processes vibration signals at varying speeds, obtaining angular domain vibration signals to minimize the offsets caused by speed changes. Second, to address the generalization limitations of deep learning models, fault data from constant speed conditions are used as the source domain for training the neural network. Covariance loss is introduced to amplify the feature differences among various classes in the source domain data. This allows the network to focus on more informative features for the classification task, thereby improving its generalization capability. Finally, the angular domain vibration signals under variable speed conditions are input into the trained model for fault classification.

The effectiveness of the proposed method is validated through several experiments. Initially, the time-frequency characteristics of vibration signals from an actual bearing inner ring fault are examined before and after angular domain resampling. Before resampling, the vibration signal intervals under variable speed conditions show significant variability. However, after resampling, the variability in the vibration intervals is significantly reduced. Furthermore, using t-SNE visualization, the study observes that networks without feature enhancement show slow gradient updates and minimal changes in feature distribution. In contrast, networks with feature enhancement exhibit continuous changes in feature distribution, even as the classification loss decreases, with increasing feature distances. The study also conducts four cross-working condition fault diagnosis experiments, comparing the proposed method with other methods. The results demonstrate that the proposed method improves fault identification accuracy by 35.04% compared to methods without angular domain resampling, especially in rolling element fault identification. When compared to methods without feature enhancement, the proposed method improves accuracy by 7.45%. Additionally, in transfer diagnosis tasks under different load conditions, the proposed method demonstrates high accuracy, recall, and F1 scores.

In conclusion, the study finds that: (1) Angular domain resampling effectively reduces time-frequency distribution differences caused by speed variations, proving its applicability and rationality in data preprocessing at different speeds. (2) The feature enhancement strategy, by increasing covariance loss between different class features, amplifies feature differences between various health status signals, enabling the network to capture more distinctive features and significantly improving generalization capability. (3) The proposed method, without requiring target domain data, achieves fault identification accuracy of up to 97.29% under variable speed conditions, demonstrating good robustness under variable load conditions.

**Keywords:** Motor bearing fault, transfer learning, convolutional neural network, angular domain resampling, feature enhancement

(编辑 郭丽军)