

http://bhxb.buaa.edu.cn jbuua@buaa.edu.cn

DOI: 10.13700/j.bh.1001-5965.2022.0631

基于领域自适应的变工况轴承故障诊断

曹洁^{1, 2, 3}, 尹浩楠¹, 雷晓刚¹, 王进花^{1, 2, 3, *}

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室, 兰州 730050;

3. 甘肃省制造信息工程研究中心, 兰州 730050)

摘 要: 针对轴承故障诊断中存在训练样本和测试样本分布不同及各类故障数据不平衡导致故障识别率低的问题, 设计了一种基于改进残差网络 (ResNet) 的领域自适应故障诊断方法。在诊断网络第 1 层使用多维度卷积结构进行特征提取, 得到不同维度的故障特征信息; 在领域自适应层采用局部最大平均差异 (LMMD) 对齐源域和目标域的分布, 获取更多细粒度信息; 使用类平衡损失函数 (CBLoss) 解决不平衡数据的训练问题, 以 Adam 优化网络实现故障诊断。实验结果表明, 所提方法可在故障样本类别不平衡下有较高的诊断结果。在 2 个轴承数据集和采集的风力发电机数据上进行实验验证, 结果表明, 所提方法具有一定的优越性, 在数据样本不平衡情况下, 诊断性能优于深度神经网络和领域自适应网络等深度迁移学习方法, 可作为一种有效的跨工况故障分析方法。

关键词: 故障诊断; 残差网络; 数据不平衡; 局部最大平均差异; 类平衡损失函数; 轴承

中图分类号: TP277

文献标志码: A

文章编号: 1001-5965(2024)08-2382-09

机械设备作为现代工业由传统制造业向智能制造业转变的重要角色之一, 能够更快地促进生产, 提高生产经济效益。机器在不间断的正常工作运行及管理工作过程中会不可避免地出现各种故障, 从而引发计划外的停机, 对经济造成严重损失, 甚至造成人员伤亡^[1]。轴承作为机械传动部件的重要组成部分, 往往最容易出现故障, 统计表明, 机械故障中有 45%~55% 为轴承故障^[2], 大量学者针对轴承故障诊断展开研究并取得了丰硕的成果。近年来, 随着工业大数据的快速发展, 基于深度学习的智能故障诊断方法发展更加迅速^[3]。其中, 基于深度学习的轴承故障诊断也被大量研究^[4-6]。但是, 这些传统的深度学习方法都需要满足以下 2 个条件: ①训练数据的分布和测试数据的分布之间存在较大的差异; ②在训练过程中需要足够多的带标签数据来对模型进行训练。当分布不同或没有足够

的数据标签时, 这些方法的性能可能会快速下降; 而设备在长期运行过程中会积累大量的未带标签的数据, 对数据进行手动标记或重新开始构建新的模型都需要耗费大量的时间和精力。

基于此, 迁移学习作为一种有效解决此类问题的方法被引入到故障诊断中。该方法主要解决目标样本标记数据稀少和域分布不一致问题, 在机器视觉、自然语言处理等领域中有较好的表现^[7-9]。文献 [10] 建立深度迁移卷积网络, 实现了在目标域上用少量的训练数据对网络进行一系列的微调。文献 [11] 采用迁移参数的方法, 将卷积神经网络 (convolutional neural network, CNN) 作为迁移网络, 实现了不同型号下轴承的故障诊断。虽然通过微调获得了更精确的诊断网络模型, 但仍未能解决目标域标签不足的问题。

为解决对样本数据进行诊断时目标域样本数

收稿日期: 2022-07-19; 录用日期: 2022-09-11; 网络出版时间: 2022-09-27 10:04

网络出版地址: link.cnki.net/urlid/11.2625.V.20220922.1751.003

基金项目: 国家重点研发计划 (2020YFB1713600); 国家自然科学基金 (62063020); 甘肃省自然科学基金 (20JR5RA463)

*通信作者. E-mail: wjh0615@lut.edu.cn

引用格式: 曹洁, 尹浩楠, 雷晓刚, 等. 基于领域自适应的变工况轴承故障诊断 [J]. 北京航空航天大学学报, 2024, 50 (8): 2382-2390.

CAO J, YIN H N, LEI X G, et al. Bearing fault diagnosis in variable working conditions based on domain adaptation [J]. Journal of Beijing University of Aeronautics and Astronautics, 2024, 50 (8): 2382-2390 (in Chinese).

据无标签的问题,在变工况故障诊断中,基于领域自适应的迁移学习方法受到了广泛的关注,其主要思想是用深层神经网络提取故障特征信息后添加自适应层来减少目标域和源域距离之间的分布差异。因此,有效测量域之间的分布距离非常重要,因为其影响到减少分布差异的性能。文献[12-14]通过计算目标域和源域之间的最大均值化差异(maximum mean discrepancy, MMD),实现了跨域故障诊断。为更好地减少域分布差异,文献[15-16]利用多核最大均值化差异(multikernel maximum mean discrepancy, MK-MMD)选择一个最优、合理的核来加强 MMD 的效果,在跨域故障诊断中取得了较好的结果。文献[17]利用 Wasserstein 距离度量分布差异适应目标域和源域,实现了变工况故障诊断。而在迁移网络的选取中,深度学习网络有着优越的性能。文献[18-20]使用 CNN 对特征进行提取,实现了在跨工况条件下的故障诊断。残差网络(residual network, ResNet)是一种 CNN 网络的改进,在残差块中通过使用短连接结构来提高深度网络的泛化能力,在故障诊断领域中受到了广泛关注。文献[21-23]以 ResNet 作为基础网络,在应用中针对不同对象及不同问题分别进行改进,取得了较好的结果。

以上基于领域自适应研究虽然得到了较高的诊断效果,但并未考虑样本数量较少及样本类别在不平衡条件下的问题。在实际应用中,能获取的样本较少,并且不同工况下各故障类别的数据不平衡^[24]。为解决由于样本数据不平衡导致的分类错误,以及样本量不足导致模型诊断精度低的问题,本文提出了一种基于改进 ResNet 的领域自适应故障诊断方法,实现了在变工况条件下对不平衡数据集的故障诊断。主要改进如下:

- 1) 在网络开始部分采用多维度卷积结构,提取多维度特征,克服单一维度特征提取信息不全的问题。
- 2) 样本局部之间的分布差异采用领域自适应

层局部最大平均差异(local maximum mean discrepancy, LMMD)来衡量,对目标域和源域的分布进行对齐操作。

3) 迁移学习网络训练中采用类平衡损失函数(class-balance loss, CBLoss)解决样本数据不平衡对模型的影响。

1 相关理论

1.1 迁移学习

迁移学习主要用于解决目标域数据少标签或无标签及源域和目标域分布不同的问题。不同工况下的故障诊断是从一组带标签的源域数据学到的分类参数通过迁移,应用到另一组未带标签的目标域数据。迁移学习中,任务和领域是最为重要的 2 个基本概念。 d 维特征空间 X 和边缘概率分布 $P(x)$ 组成领域 D , 其中, $D = \{X, P(x)\}$, $x \in X$ 。设置在一定工作条件下带标签的数据作为源域样本 $D_s = \{X^s, P(x^s)\}$, 其他条件下的无标签数据作为目标域样本 $D_t = \{X^t, P(x^t)\}$ 。由于源域和目标域的工作条件不同, 2 个域中的数据分布存在很大的差异, 即 $P(x^s) \neq P(x^t)$ 。故障诊断的目标是任务, 其由一个预测函数 $f(x)$ 和标签空间 y 组成, 其中, $T = \{Y, f(x)\}$, $f(x) = P(y|x)$ 为条件概率分布, $y \in Y$ 。由于不同域数据之间的类别相同, 令其标签空间也相同, 即 $Y^s = Y^t$, 条件概率也相同, 即 $P(y^s|x^s) = P(y^t|x^t)$ 。通过对源数据样本进行训练, 建立由源数据特征空间 X^s 到标签空间 Y^s 之间非线性的映射关系: $X^s \rightarrow Y^s$, 从而获取其中的故障诊断知识。

1.2 子领域自适应

传统的领域自适应方法主要通过对齐全局目标域和源域之间的分布,从而学习到全局域的位移,并未考虑不同域下同一类别子领域之间的特殊关系,导致迁移学习性能不理想。经过全局域自适应后,2 个域的分布基本相同,但不同子领域的数据过于接近,难以进行准确分类,如图 1 左部分所示。子领域自适应的核心是学习局部域转移,如




图 1 领域自适应图解

Fig. 1 Domain adaptation diagram

图 1 右部分所示,可以按照不同域分别对齐同一类别域数据。因此,针对变工况条件,利用子领域自适应方法,能够更好地提高分类精度。

1.3 残差网络

ResNet 的主要思想是: 将一个通道直接引入网络, 将网络模型的输入直接传递给后续层, 从而学习到前一层网络输出的残差, 解决了模型在训练过程中存在梯度消失及深层网络训练难度较大的问题。图 2 为浅层残差网络中残差块的结构。残差块由短连接、卷积层 Conv、批处理归一化层 BN 和激活函数 ReLu 构成。图 2 中, x 为输入。设 $F(x)$ 为卷积路径的非线性函数, 则残差块的输出可表示为

$$u = F(x) + x \tag{1}$$

其残差为 $F(x) = u - x$, 该网络训练的目标是使残差 $F(x)$ 的值尽可能为 0, 从而避免随网络深度加深而产生的精度下降问题。




图 2 残差块结构
Fig. 2 Residual block structure

2 基于改进 ResNet 的子领域自适应故障诊断

实际生产中, 不同工况下采集到的轴承故障信号分布是不一致的。由于轴承每个部位发生故障的频率不同, 采集到的每一类故障样本数量也会不同。目前, 大量基于 ResNet 的迁移学习主要采用在图像领域预训练好的网络参数进行迁移, 没有针对轴承故障数据, 缺乏针对性。基于此, 本文提出一种基于变工况下类别不平衡深度子领域自适应迁移学习方法。该方法使用改进 ResNet 作为主体诊断模型, 残差块参数如表 1 所示。自适应层使用 LMMD 减少分布差异, 对齐不同子领域; 网络训练使用类平衡损失函数消除故障样本分布不平衡对模型的影响。

表 1 残差块参数
Table 1 Residual block parameters

残差块	残差块参数	
	Conv1	Conv2
Block1×2	Conv(3,3,1,16)	Conv(3,3,1,32)
Block2×2	Conv(3,3,1,32)	Conv(3,3,1,64)
Block3×2	Conv(3,3,1,64)	Conv(3,3,1,128)

2.1 多维特征提取模块

为获取更多输入特征信息, 采用多维特征提取模块提取更深层次的特征, 结构如图 3 所示。区别传统 CNN 单通道特征提取, 本文使用的多维特征提取模块在输入之后, 采用并行的 3 个卷积层, 使用不同大小的卷积核对提取不同维度下特征信息, 使用标准化 BN 和 ReLu 后, 通过 Concat 将特征维度拼接到一起, 通过最大池化层输出提取到的特征信息。




图 3 多维特征提取模块
Fig. 3 Multidimensional feature extraction module

2.2 子领域自适应函数及类不平衡损失

2.2.1 子领域自适应函数

通过对相关子领域分布进行对齐, 不仅可以调整全局区域分布, 还可以匹配不同工作条件下的子类别缺陷分布, 在训练过程中, 模型的泛化能力和鲁棒性更好。但在实际中, 目标域中的数据往往是无标签的。针对该问题, 使用训练好的模型概率来生成目标域的伪标签, 传统的用来度量目标域和源域之间的分布差异通常采用 MMD, 本文针对迁移学习中子领域的自适应问题, 使用 LMMD 对模型进行优化^[25]。

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

式中: $\hat{d}_H(p, q)$ 为全局域自适应损失; C 为样本类别数量; ϕ 为原始空间到希尔伯特空间的映射; ω_i^{sc} 和

ω_j^c 分别为属于 c 类的 x_i^s 和 x_j^t 的权重。 $\sum_{i=1}^{n_s} \omega_i^{sc}$ 和 $\sum_{j=1}^{n_t} \omega_j^c$ 都等于 1, 且 $\sum_{x_i \in D} \omega_i^c \phi(x_i)$ 是类别 c 的加权和, n_s 、 n_t 分别为 2 种分布样本的总数。样本 x_i^s 的权重 ω_i^{sc} 计算如下:

$$\omega_i^{sc} = \frac{y_{ic}}{\sum_{(x_j, y_j) \in D} y_{jc}} \quad (3)$$

式中: y_{ic} 为输入 y_i 的第 c 类标签。源域样本通过计算真实标签 y_i^s 得到每个样本的权重 ω_i^{sc} 。由于目标域无标签, 神经网络 $\hat{y}_i = f(x_i)$ 输出并不是确定的, 而是一个概率分布, 表示将样本 x_i 预测为 c 类的概率, 目标域的伪标签用网络预测标签 $\hat{y}_i^t$ 表示, 进而计算目标域的权重 ω_j^c 。为实现自适应的高层网络, 其中的激活值 z 需要明确。存在 n_s 个具有标签的源域 D_s 服从概率值为 p 的概率和 n_t 个不含标签的目标域 D_t 服从概率值 q 的概率, 深层神经网络会在 l 层中产生 $\{z_i^s\}_{i=1}^{n_s}$ 和 $\{z_j^t\}_{j=1}^{n_t}$ 的激活值。故推导出子领域的自适应函数为

$$\hat{d}_l(p, q) = \frac{1}{C} \sum_{c=1}^C \left(\sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_i^{sc} \omega_j^{sc} k(z_i^s, z_j^s) + \sum_{i=1}^{n_t} \sum_{j=1}^{n_t} \omega_i^{tc} \omega_j^{tc} k(z_i^t, z_j^t) - 2 \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} \omega_i^{sc} \omega_j^{tc} k(z_i^s, z_j^t) \right) \quad (4)$$

式中: $k(z_i^s, z_j^s)$ 为源域和目标域的样本。

2.2.2 类平衡损失函数

传统的故障诊断中, 通常采用的故障数据集是人为构建的平衡数据集, 即每类故障样本数量相同。然而, 实际生产中采集到的数据样本, 各类别的数据不一定均衡, 因为一般情况下, 设备是健康的, 所以采集的数据中以健康样本居多, 故障样本占少量。不平衡数据集及样本量不足会导致网络在提取拥有大量样本的故障状态特征时出现过拟合, 而少量故障种类的样本量不足以支撑深层网络学习到比较稳定的泛化特征, 导致故障分类的精度不足。在现有研究中, 一般采用重采样和加权采样的方法来解决该问题。重采样作为一种有效处理不平衡数据集的方法, 可以解决大多数问题。欠采样会导致特征信息的缺失, 而过采样会导致过拟合, 并且重新抽样会增加重复的样本, 降低网络的训练速度。重加权的方法通常是对损失函数进行改进, 以解决不平衡数据问题, 这类方法实现方便且效果显著。为解决数据不平衡条件下的分类问题, 文献 [26] 提出了一种 CBLoss 函数, 其主要思想是利用有效样本量 E_n 对损失函数反向加权。对于

不同种类的故障样本, 第 j 类的有效样本量可表示为

$$E_{n_j} = \frac{1 - \beta_j^{n_j}}{1 - \beta_j} \quad (5)$$

$$\beta_j = \frac{N_j - 1}{N_j} \quad (6)$$

式中: n_j 为第 j 类故障的样本数量; N_j 为第 j 类故障的有效样本数; β 为需要调节的超参数。

为平衡第 j 类故障的损失, 引入反比因子 $1/E_{n_j}$, 因此, CBLoss 函数可以表示为

$$L_{CB}(p, y) = \frac{1}{E_{n_y}} L(p, y) = \frac{1 - \beta_y}{1 - \beta_y^{n_y}} L(p, y) \quad (7)$$

式中: n_y 为 y 类的样本数量; $L(p, y)$ 为常用的损失函数, 分类损失函数使用 focal。

$$F(z, y) = - \sum_{i=1}^C (1 - p_i^t)^\gamma \lg p_i^t \quad (8)$$

式中: $p_i^t = 1/[1 + \exp(-z_i^t)]$, i 和 t 分别为样本 z 的种类和数量; γ 为需要调节的超参数。

由此可以得到本文中的类平衡损失:

$$L_{CBfocal}(z, y) = - \frac{1 - \beta}{1 - \beta^{n_y}} \sum_{i=1}^C (1 - p_i^t)^\gamma \lg p_i^t \quad (9)$$

2.3 子领域自适应故障诊断网络模型

本文方法模型如图 4 所示。首先, 将传感器采集到的方位一维信号数据转化为二维矩阵形式; 然后, 为缩短模型的训练时间, 使用源域信号对模型进行预训练, 模型训练完成后, 保存优化好的模型




图 4 子领域故障诊断模型

Fig. 4 Sub-domain fault diagnosis model

参数,在分类层前加入自适应层,采用 LMMD 算法对模型进行子领域自适应;最后,采用 Softmax 函数对故障类型进行分类。

训练过程需要优化的目标函数为

$$L_{total} = \min_f \frac{1}{n_s} \sum_{i=1}^{n_s} L_{CBfocal}(z,y) + \lambda \mu \sum_{l \in L} \hat{d}_l(p,q) \quad (10)$$

式中: L 为总自适应层数,本文设置 $L=1$; 试验可得超参数 $\mu=0.3$; $\lambda>0$ 为超参数,表示为

$$\lambda = \frac{2}{1 + e^{-10m/M}} \quad (11)$$

其中: m 为当前训练轮数; M 为总的训练轮数。

2.4 故障诊断流程

本文方法整体故障诊断流程如图 5 所示。首先,对采集的一维时序信号进行数据预处理,选取 1 024 个点作为一个样本,将其转换成 32×32 的矩阵,便于网络计算。划分数据集后,将无标签的目标域数据和有标签的源域数据分别划分为测试集和训练集。其次,利用源域数据对改进后的 ResNet 模型进行预训练,提高模型训练时的速度,后期训练故障诊断模型时可直接读取保存好的网络参数。在模型训练过程中,有标签的训练集数据和无标签的测试集数据比例设置为 5:1,用来对齐源域和目标域。batchsize 设置为 64。将改进后的 ResNet 作为特征提取器提取可迁移特征,利用 LMMD

尽可能减少源域和目标域之间的差异性。采用 Softmax 作为分类器,对不同工况下轴承健康状态进行分类。当模型训练到最优后,对目标域的测试集样本进行分类,得到诊断结果。

3 实验验证

3.1 实验 1

3.1.1 数据集

本文选用美国凯斯西储大学轴承公开数据集,其实验设备如图 6 所示。一共存在 4 种轴承状态,分别为正常(N)、内圈故障(IRF)、外圈故障(ORF)和滚子故障(RF)。采样频率为 12 000 Hz。每种故障类型存在 2.54, 5.08, 7.62 cm 这 3 种不同的损伤直径,共 10 种状态。故障数据在 4 种不同的负载 0, 0.735, 1.47, 2.205 kW 下采集,将不同的工作条件分别用 A、B、C、D 表示。不同工况下的数据按照不同的故障类别获取所需样本,具体如表 2 所示。




图 6 美国凯斯西储大学轴承实验台

Fig. 6 Bearing test bench of American Case Western Reserve University

表 2 数据集设置

Table 2 Dataset settings

故障类型	尺寸/cm	训练集数量	测试集数量
正常		200	150
	2.54	150	100
	5.08	150	100
滚子故障	2.54	150	100
	5.08	150	100
	7.62	100	50
内圈故障	2.54	100	50
	5.08	100	50
	7.62	100	50




图 5 整体故障诊断流程

Fig. 5 Overall fault diagnosis process

在不同负载下工作,会导致振动数据分布不一致。为验证本文方法的准确性,将其应用于不同负载工况。本文采用设备驱动端采集的轴承数据,共 12 个迁移任务: A→B, A→C, A→D, B→A, B→C, B→D, C→A, C→B, C→D, D→A, D→B, D→C。针对无监督学习转移任务,训练集为带标签的源域数

据, 测试集为无标签的目标域数据, 比例为 5:1。

3.1.2 与其他模型的比较分析

为验证本文模型在变工况条件下进行故障诊断的优势, 将其与传统迁移学习模型进行对比, 包括联合分布适应模型 (joint distribution adaptation, JDA)^[27]、LeNet-5、深度 CORAL(deep-CORAL, D-CORAL)^[28]、领域自适应神经网络 (domain adaptive

neural network, DaNN)^[29]。其中, LeNet-5 为 5 层 CNN, 模型使用源域样本直接训练。D-CORAL 和 DaNN 分别用 CORAL 和 MMD 作为领域自适应度量准则, 并且都使用本文训练好的 ResNet 模型提取特征, 通过反向传播优化分类器。本文模型与其他模型在不同条件下的故障诊断结果对比如表 3 所示。

表 3 不同方法诊断精度
Table 3 Diagnostic accuracy of different methods

方法	准确率/%												平均准确率
	A→B	A→C	A→D	B→A	B→C	B→D	C→A	C→B	C→D	D→A	D→B	D→C	
JDA ^[27]	71.3	68.5	70.2	66.8	69.9	73.6	70.4	72.6	71.2	69.1	68.5	73.6	70.5
LeNet-5	82.1	83.9	79.7	81.5	80.3	84.4	80.3	82.1	81.9	77.6	81.4	83.2	81.5
D-CORAL ^[28]	98.4	96.8	88.9	96.5	97.3	95.6	91.3	97.2	98.7	87.6	93.6	95.7	94.8
DaNN ^[29]	97.0	97.5	94.4	96.5	98.2	98.6	95.2	97.6	98.1	89.1	96.2	97.2	96.3
本文方法	99.4	98.8	99.1	99.3	98.5	99.8	98.2	99.1	99.5	98.4	99.7	99.3	99.1

从表 3 可以看出, JDA^[27] 模型的分类平均准确率为 70.5%, 验证了该模型在不同负载条件下的轴承故障诊断效果一般。而 LeNet-5 由于卷积层数较少, 数据类别不平衡, 导致诊断结果不理想, 平均准确率只有 81.5%。作为深度迁移模型的 D-CORAL^[28] 和 DaNN^[29], 在相同条件下, 平均准确率分别为 94.8% 和 96.3%, 这主要是因为使用了领域自适应方法。

3.1.3 类平衡损失函数验证

为验证 CBLoss 函数在网络诊断模型中的效果, 本节采用 A→B 这一工况进行实验。在建立好的模型中分别使用传统的交叉熵损失函数和 CBLoss 进行对比, 实验结果分别如图 7(a)、(b) 所示。

从图 7 中可以看到, 2 种模型都有较好的分类效果。交叉熵损失模型在第 3、4、5 标签类别中出现较多误判, 而使用 CBLoss 函数较好地解决了这一问题。说明 CBLoss 函数利用各类别的有效样本量对损失函数进行重新加权, 能够有效消除样本数的分布差异, 降低样本不平衡分布对网络模型故障识别能力造成的影响。

3.2 实验 2

为进一步验证本文方法的有效性, 采用帕德伯恩的轴承数据进行验证^[30]。实验台由电机、测转矩轴、轴承测试模块、飞轮、负载电机等 5 个部分组成, 如图 8 所示。

在轴承测试模块中, 安装不同损伤的实验轴承, 生成 4 种不同工况下的实验数据, 如表 4 所示。根据损伤的位置和严重程度, 实验轴承的健康状态可分为 3 种: 正常 (N)、内圈损伤 (IR)、外圈损伤 (OR)。包含两相电流信号和一组振动信号, 为区别 3.1 节实验 1, 实验选取第一相电流的数据。采样频率为





图 7 2 种损失函数混淆矩阵

Fig. 7 Confusion matrix of two loss functions



1. 电机; 2. 测转矩轴; 3. 轴承测试模块; 4. 飞轮; 5. 负载电机。

图 8 帕德伯恩轴承实验台

Fig. 8 Paderborn bearing test bench

表 4 不同工况详细信息

Table 4 Details of different working conditions			
编号	转速/(r·min ⁻¹)	扭矩/(N·m)	径向负载/N
0	1 500	0.7	1 000
1	900	0.7	1 000
2	1 500	0.1	1 000
3	1 500	0.7	400

64 kHz, 包含 6 个正常轴承、12 个具有人为损坏故障的轴承、14 个采用加速寿命试验损坏故障的轴承。

为更接近实际工况, 本文采用损伤数据作为源域数据, 真实损伤数据作为目标域数据。源域数据为编号 0 工况下人工损伤数据, 数据代码为 K001 (正常)、KI01 (内圈故障)、KA01 (外圈故障)。其他工况下加速寿命试验损坏数据为目标域数据。迁移任务目标域数据代码如表 5 所示。

实验方案设计及参数与美国凯斯西储大学轴承数据集实验一致, 考虑到 2 组实验采用的信号类型不同, 在实验样本数量设计选择不同比例, 具体如表 6 所示。不同方法的诊断精度如图 9 所示, 可以看出, 在使用不同实验台及电流信号作为实验对象时, 诊断结果相对美国凯斯西储大学振动信号有所降低, 其主要原因是电流信号中包含由故障产生的谐波信号, 对诊断结果有影响。相对而言, 较其他方法, 如 JDA^[27]、LeNet-5 未使用迁移方法, 以及经典的 D-CORAL^[28] 和 DaNN^[29] 迁移学习方法, 本

表 5 目标域数据代码

Table 5 Target domain data codes			
迁移任务	正常	内圈故障(OR)	外圈故障(IR)
0-1	K002	KI04	KA04
0-2	K003	KI14	KA15
0-3	K004	KI16	KA22

表 6 轴承数据集划分

Table 6 Bearing dataset partitioning		
故障类型	训练集数量	测试集数量
正常	500	300
内圈损伤	200	100
外圈损伤	100	50




图 9 不同方法准确率对比

Fig. 9 Accuracy comparison of different methods

文方法诊断准确率有明显提升。

3.3 实验 3

为进一步验证本文所提迁移模型的泛化能力, 在甘肃酒泉某风电场采集的风力发电机电流数据上进行实验验证。实验选取了 3 种故障类型, 数据代码为故障 I、故障 II、故障 III, 迁移任务目标域数据代码如表 7 所示, 在 3 种不同风速条件下(用 a、b、c 表示)进行迁移学习。

数据集的划分如表 8 所示, 针对所采集的电流信号, 训练集和测试集划分的比例为 2:1。

实验方案设计参数与美国凯斯西储大学轴承数据集实验一致, 实验结果取 10 次平均值, 如表 9

表 7 目标域数据集划分

Table 7 Target domain dataset partitioning			
迁移任务	故障类型		
a-b	故障 I	故障 II	故障 III
a-c	故障 I	故障 II	故障 III

表 8 风机数据集划分

Table 8 Wind turbine dataset partitioning		
故障类型	训练集数量	测试集数量
故障 I	200	100
故障 II	100	50
故障 III	50	25

表 9 风机数据不同方法诊断精度

Table 9 Diagnostic accuracy of wind turbine data of different methods		
方法	准确率/%	
	a-b	a-c
JDA ^[27]	70.7	65.6
LeNet-5	79.4	81.3
D-CORAL ^[28]	96.9	95.7
DaNN ^[29]	95.8	96.3
本文方法	98.2	98.4

所示。本文方法相比于其他方法能够有效提高故障诊断的准确率,同时验证了本文方法的有效性 & 本文模型具有良好的泛化能力。

4 结 论

本文提出了一种基于可变工况条件下子领域自适应的轴承诊断方法,其目标是解决可变运行条件下收集的轴承故障信号特征和不平衡数据类别分布不协调的问题。通过相关实验进行对比验证得出以下结论:

- 1) 第 1 层多维特征提取模块构建的 ResNet 模型,能够对不同工况下的轴承故障信号提取更深层次的特征。
- 2) 自适应层采用子领域对齐的方法,减少目标域与源域之间的分布差异,解决了全局领域自适应对齐时发生同类别距离减小使诊断结果出现偏差的问题,采用 LMMD 算法生成伪标签解决目标域无标签情况。
- 3) 通过采用 CBLoss 替换交叉熵损失,解决了变工况条件下样本数据类别不平衡问题。通多实验对比,证明了本文方法具有良好的鲁棒性和泛化能力。

参考文献 (References)

[1] JIAO J Y, ZHAO M, LIN J, et al. Hierarchical discriminating sparse coding for weak fault feature extraction of rolling bearings[J]. Reliability Engineering & System Safety, 2019, 184: 41-54.

[2] LIM D H, KIM K S. Development of deep learning-based detection technology for vortex-induced vibration of a ship's propeller[J]. Journal of Sound and Vibration, 2022, 520: 116629.

[3] YU L, QU J L, GAO F, et al. A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM[J]. Shock and Vibration, 2019, 2019: 2756284.

[4] JIN T T, YAN C L, CHEN C H, 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, 2023, 124(11): 3701-3712.

[5] LI H. Deeplearning for natural language processing: Advantages and challenges[J]. National Science Review, 2018, 5(1): 24-26.

[6] KHAN S, YAIRI T. A review on the application of deep learning in system health management[J]. Mechanical Systems and Signal Processing, 2018, 107: 241-265.

[7] WANG J Y, MO Z L, ZHANG H, et al. A deep learning method for bearing fault diagnosis based on time-frequency image[J]. IEEE Access, 2019, 7: 42373-42383.

[8] HASSAN S M, MAJI A K, JASIŃSKI M, et al. Identification of plant-leaf diseases using CNN and transfer-learning approach[J]. Electronics, 2021, 10(12): 1388.

[9] PATEL V M, GOPALAN R, LI R N, et al. Visual domain adapta-

tion: A survey of recent advances[J]. IEEE Signal Processing Magazine, 2015, 32(3): 53-69.

[10] KERMANY D S, GOLDBAUM M, CAI W J, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning[J]. Cell, 2018, 172(5): 1122-1131.

[11] 张西宁, 余迪, 刘书语. 基于迁移学习的小样本轴承故障诊断方法研究[J]. 西安交通大学学报, 2021, 55(10): 30-37.

ZHANG X N, YU D, LIU S Y. Fault diagnosis method for small sample bearing based on transfer learning[J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 30-37(in Chinese).

[12] LI F D, CHEN J L, PAN J, et al. Cross-domain learning in rotating machinery fault diagnosis under various operating conditions based on parameter transfer[J]. Measurement Science and Technology, 2020, 31(8): 085104.

[13] ZHU J, CHEN N, SHEN C Q. A new deep transfer learning method for bearing fault diagnosis under different working conditions[J]. IEEE Sensors Journal, 2020, 20(15): 8394-8402.

[14] WEN L, GAO L, LI X Y. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49(1): 136-144.

[15] GUO L, LEI Y G, XING S B, 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, 2019, 66(9): 7316-7325.

[16] CHE C C, WANG H W, NI X M, et al. Domain adaptive deep belief network for rolling bearing fault diagnosis[J]. Computers & Industrial Engineering, 2020, 143: 106427.

[17] SHAO J J, HUANG Z W, ZHU J M. Transfer learning method based on adversarial domain adaption for bearing fault diagnosis[J]. IEEE Access, 2020, 8: 119421-119430.

[18] 康守强, 刘旺辉, 王玉静, 等. 基于深度在线迁移的变负载下轴承故障诊断方法[J]. 控制与决策, 2022, 37(6): 1521-1530.

KANG S Q, LIU W H, WANG Y J, et al. Bearing fault diagnosis method under variable load based on deep online migration[J]. Control and Decision, 2022, 37(6): 1521-1530(in Chinese).

[19] ZHAO C, LIU G K, SHEN W M, et al. A multi-representation-based domain adaptation network for fault diagnosis[J]. Measurement, 2021, 182: 109650.

[20] WANG X, SHEN C Q, XIA M, et al. Multi-scale deep intra-class transfer learning for bearing fault diagnosis[J]. Reliability Engineering & System Safety, 2020, 202: 107050.

[21] FU S F, CAI F H, WANG W. Fault diagnosis of photovoltaic array based on SE-ResNet[J]. Journal of Physics: Conference Series, 2020, 1682(1): 012004.

[22] GROVER C, TURK N. A novel fault diagnostic system for rolling element bearings using deep transfer learning on bispectrum contour maps[J]. Engineering Science and Technology, an International Journal, 2022, 31: 101049.

[23] ZOU Y S, LIU Y Z, DENG J L, et al. A novel transfer learning method for bearing fault diagnosis under different working conditions[J]. Measurement, 2021, 171: 108767.

[24] LESSMEIER C, KIMOTHO J K, ZIMMER D, et al. Condition-monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification[C]//Proceedings of the European

Conference of the Prognostics and Health Management Society. ST Roch: PHM Society, 2016: 1-17.

[25] ZHU Y C, ZHUANG F Z, WANG J D, et al. Deep subdomain adaptation network for image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2021, 32(4): 1713-1722.

[26] CUI Y, JIA M L, LIN T Y, et al. Class-balanced loss based on effective number of samples[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2019: 9260-9269.

[27] WANG Y X, YAN J, YANG Z, et al. A domain adaptive deep transfer learning method for gas-insulated switchgear partial discharge diagnosis[J]. IEEE Transactions on Power Delivery, 2022, 37(4): 2514-2523.

[28] LI R R, LI S M, XU K, et al. Deep domain adaptation with adversarial idea and coral alignment for transfer fault diagnosis of rolling bearing[J]. Measurement Science and Technology, 2021, 32(9): 094009.

[29] GHIFARY M, KLEIJN W B, ZHANG M J. Domain adaptive neural networks for object recognition[C]//Proceedings of the Pacific Rim International Conference on Artificial Intelligence. Berlin: Springer, 2014: 898-904.

[30] LI X D, HU Y, ZHENG J H, et al. Central moment discrepancy based domain adaptation for intelligent bearing fault diagnosis[J]. Neurocomputing, 2021, 429: 12-24.

Bearing fault diagnosis in variable working conditions based on domain adaptation

CAO Jie^{1, 2, 3}, YIN Haonan¹, LEI Xiaogang¹, WANG Jinhua^{1, 2, 3, *}

- (1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. Key Laboratory of Gansu Advanced Control of Industrial Processes, Lanzhou 730050, China;
3. Gansu Manufacturing Information Engineering Research Center, Lanzhou 730050, China)

Abstract: This research develops a domain adaptive fault diagnosis method based on an enhanced residual network (ResNet) to address the issues that the distribution of training samples and test samples differs in bearing fault diagnosis and the imbalance of different fault data results in a low fault recognition rate. First, the multi-dimensional convolution structure is used for feature extraction in the first layer of the diagnosis network to obtain fault feature information of different dimensions. Then, the local maximum mean difference (LMMD) is used in the domain adaptation layer to align the distribution of the source and target domains, to obtain more fine-grained information. Finally, the class-balanced loss (CBLoss) function is used to solve the training problem of unbalanced data, and the Adam optimization network is used to achieve fault diagnosis. The experimental findings demonstrate that, even in cases when fault sample categories are unbalanced, the enhanced approach suggested in this work can produce better diagnosis outcomes. Experiments are carried out on two bearing datasets and collected wind turbine data. The results show that the improved method has certain advantages, and its diagnostic performance is better than other deep transfer learning methods in the case of imbalanced data samples. It can be used as an effective cross-condition failure analysis method.

Keywords: fault diagnosis; residual network; data imbalance; local maximum mean difference; class-balanced loss; bearings