

复杂工况下的轴承故障诊断方法综述

马新娜^{1,2}, 张策^{1,3}, 李豪^{1,3}, 何畔^{1,3}

(1. 石家庄铁道大学信息科学与技术学院; 2. 石家庄铁道大学河北省电磁环境效应与信息处理学科重点实验室;
3. 石家庄铁道大学石家庄市人工智能重点实验室, 河北石家庄 050043)

摘要: 轴承是旋转机械中的重要部件, 在现实应用中, 轴承的运行环境复杂多变。复杂工况条件下对轴承的故障进行准确判断是一个研究热点, 因此针对复杂工况下轴承故障诊断中的样本不平衡和变工况下的迁移学习问题展开论述。在样本不平衡问题中, 从重采样技术和基于模型的生成方法两种角度, 分析所涉及方法的优缺点及适用场景。在迁移学习部分, 详细解释了基于样本、特征和参数的迁移方法, 并探讨了其在变工况轴承故障诊断中的应用前景。此外, 还展望了未来可能涌现的新技术和方法, 如结合深度学习和领域自适应的算法, 以应对更复杂的工况和数据情境。旨在为轴承故障诊断领域的研究者提供参考, 以进一步提升模型诊断的准确性和可靠性。

关键词: 复杂工况; 轴承故障诊断; 样本不平衡; 迁移学习

DOI: 10.11907/tj.dk.241564

中图分类号: TP18

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)009-0009-10



Review of Bearing Fault Diagnosis Methods under Complex Working Conditions

MA Xinna^{1,2}, ZHANG Ce^{1,3}, LI Hao^{1,3}, HE Pan^{1,3}

(1. School of Information Science and Technology, Shijiazhuang Railway University;

2. Hebei Key Laboratory of Electromagnetic Environmental Effects and Information Processing, Shijiazhuang Railway University;

3. Shijiazhuang Key Laboratory of Artificial Intelligence, Shijiazhuang Railway University, Shijiazhuang 050043, China)

Abstract: Bearing is an important part of rotating machinery. In practical applications, the operating environment of bearing is complex and changeable. It is a research hotspot to accurately judge the bearing fault under complex working conditions. Therefore, the sample imbalance in bearing fault diagnosis under complex working conditions and the transfer learning under variable working conditions are discussed. In the problem of sample imbalance, the advantages, disadvantages and applicable scenarios of the involved methods are analyzed from the perspectives of resampling technology and model-based generation method. In the part of transfer learning, the transfer method based on samples, features and parameters is explained in detail, and its application prospect in variable condition bearing fault diagnosis is discussed. In addition, it also looks forward to new technologies and methods that may emerge in the future, such as algorithms that combine deep learning and domain adaptation to deal with more complex working conditions and data scenarios. The purpose is to provide reference for researchers in the field of bearing fault diagnosis, so as to further improve the accuracy and reliability of model diagnosis.

Key Words: complex working conditions; bearing fault diagnosis; sample imbalance; transfer learning

0 引言

轴承是旋转机械设备中的关键部件, 其稳定运行直接

关系到设备的性能和寿命。然而, 由于工作环境的复杂性以及长期运行带来的磨损, 轴承往往容易出现各种问题, 如裂纹、失效等。因此, 及时、准确地诊断和预测轴承故障对于预防设备损坏、提高生产效率和保障人员安全来说至

收稿日期: 2024-07-01

扫描二维码阅读全文:



基金项目: 国家自然科学基金项目(12172234); 河北省自然科学基金项目(A2021210022); 河北省“三三三人才”资助项目(A202101018)

作者简介: 马新娜(1978-), 女, 博士, CCF会员, 石家庄铁道大学信息科学与技术学院教授、硕士生导师, 研究方向为模式识别、故障诊断; 张策(2000-), 男, CCF会员, 石家庄铁道大学信息科学与技术学院硕士研究生, 研究方向为数据系统与分析、故障诊断; 李豪(1999-), 男, 石家庄铁道大学信息科学与技术学院硕士研究生, 研究方向为数据系统与分析、故障诊断; 何畔(2000-), 男, 石家庄铁道大学信息科学与技术学院硕士研究生, 研究方向为数据系统与分析、故障诊断。本文通讯作者: 张策。

关重要,如何在复杂工况条件下准确判断轴承故障也成为当前的研究热点。本文旨在分析复杂工况下样本不平衡和变工况迁移学习对轴承故障诊断的影响,探索相关解决方法,并展望了未来的发展方向。

1 复杂工况下的轴承工作环境

滚动轴承在现代机械设备中扮演着关键角色,其基本作用有支撑旋转部件、降低摩擦、承受负荷和改善机械性能。通过使用滚珠、滚柱或其他滚动体,滚动轴承能够有效降低接触面上的摩擦力,不仅提升了机械系统的效率,而且减少了能量损失和热量生成。在负荷承受方面,滚动轴承能够处理径向和轴向负荷,确保机械系统平稳地传递力量和载荷。该方式不仅提升了机械系统运行的稳定性和精度,而且延长了其使用寿命。但是,滚动轴承运转环境复杂多变、工况种类繁多,对轴承的性能和可靠性带来较大挑战。最常见的工况是受各种因素影响的温度极端变化,在极端高温条件下,轴承的润滑剂可能会因温度升高而失去润滑能力,导致摩擦和磨损加剧。同时,高温也可能引起材料的膨胀或变形,影响轴承的精度和使用寿命。相反,在极端低温环境下,润滑剂的粘度增加,可能导致润滑不足,而且轴承材料的脆性增加,可能导致早期失效。因此,在以上环境中需要使用耐高温或低温的材料和润滑剂,以确保轴承的稳定运行。

特定应用场景下的滚动轴承处于特殊工况下,例如,在高速旋转场景中,轴承需要承受较大的离心力和高速带来的额外热量,因此需要优化其润滑系统和热管理设计细节;而在低转速应用中,轴承可能面临润滑不充分的问题,从而增加磨损,因此需要强化其润滑供给与磨损抑制设计。针对这些特殊工况,轴承设计必须满足特定的性能标准。

同一滚动轴承会随机械设备的运转状态变化,处于动态多变的工况中。最常见的多变工况包括负荷波动、转速变化以及环境条件的动态变化。机械系统在实际运行中可能经历负荷的周期性变化,如生产设备的负荷会随着操作模式的不同而波动。此外,系统的转速也可能根据负荷变化或操作需求而波动,这对轴承的润滑系统提出了更高要求。温度和湿度等环境条件也可能随时间发生变化,从而影响轴承的性能和寿命。为了应对这些多变的工况,设计师需要采用自适应的润滑技术、实时监测系统以及能够应对环境变化的材料,以保持轴承在各种条件下的稳定性和可靠性。

2 样本不平衡问题

受轴承维护标准的限制,真实场景中采集到的故障轴承运行数据十分有限,导致故障样本稀少。因此,在轴承

故障诊断中,常常会面临不同类别样本数量差异巨大的问题。这种样本不平衡现象可能导致模型在训练时对少数类别样本的学习不足,从而影响模型的性能和泛化能力。在解决样本不平衡问题的研究中,本文主要探讨了两种方法:重采样技术和基于模型的样本生成方法。重采样技术旨在通过上采样少数类别样本或下采样多数类别样本来平衡类别分布。基于模型的样本生成方法则通过对模型进行改进和添加不同的损失函数来生成高质量的样本,以进一步改善模型的学习效果和准确率。

2.1 重采样技术

经典的合成少数类过采样技术(Synthetic Minority Oversampling Technique, SMOTE)通过在少数类样本间进行线性随机插值生成新样本,从而使原始数据分布均衡。但是SMOTE方法存在过度合成样本、类别间信息丢失、对噪声敏感和计算成本高等问题,所以文献[1]在此基础上对SMOTE方法进行改进,提出了Kmeans-SMOTE算法。文献[2]在SMOTE的基础上采用边界合成过采样算法(Smote-Borderline)重点对边界样本进行过采样,生成的样本集中在决策边界区域,加强了分类器对边界的学习,减少了噪声影响。文献[3]采用随机重叠采样数据增强方法对数据集中的每个样本或多个样本进行重复采样,从而扩充了数据集规模。该方法通过生成新样本,提升了数据的多样性,有助于提高模型的泛化能力和鲁棒性。文献[4]为了解决不同种类故障数据的边界混淆及类内不平衡问题,提出高斯混合聚类模型合成少数类过采样技术。高斯混合聚类模型是一种基于概率的聚类方法,通过将数据集划分为多个不同的簇(cluster),并假设每个簇可以用一个高斯分布来表示,从而将整个数据集视为多个高斯分布的线性组合。首先使用高斯混合模型(Gaussian Mixture Model, GMM)对少数类样本进行聚类,以获得簇的划分。为了进一步解决类内样本不平衡问题,又采用簇内样本点数量与其他样本点所构成超球体体积的比例型函数,即簇密度分布函数,通过该函数调节样本点权重,以改善聚类效果,并提高模型的鲁棒性。最后根据得到的采样权重对不同簇进行SMOTE过采样,以解决少数类样本簇内不平衡问题。簇密度分布函数如下:

$$\text{density}(C_i) = \frac{N_{C_i}}{\text{vol}(S(r_i))} \quad (1)$$

其中, N_{C_i} 为簇中样本点个数; $\text{vol}(S(r_i))$ 为簇中样本点构成的超球体体积; r_i 为簇中离质心最远的样本点到质心的欧氏距离; C_i 为第*i*个簇,簇密度分布函数值越大,代表簇中的数据分布越密集。

之后,采用改进的SMOTE算法对每个簇进行过采样,并根据簇密度分布函数确定采样权重,以确保采样过程更具针对性。针对边界混淆问题,额外引入Tomek's Links数据清洗技术对生成的样本进行清洗,去除因过采样而引入的噪声数据及重叠样本。清洗后再次应用SMOTE算法

对数据进行过采样,并进一步清洗,以生成更高质量的样本。通过重复执行聚类、过采样和数据清洗步骤,逐步优化数据集质量与分类边界,最终提高模型的整体性能。文

献[5]基于数据增强算法实现训练集扩充,通过无参数化剪切翻转方式,以极低的计算成本构造了拓展数据集。重采样技术方法比较如表 1 所示。

Table 1 Comparison of resampling techniques and methods

表 1 重采样技术方法比较

方法	优点	局限性
合成少数类过采样 (SMOTE)	实现简单,易于理解和应用	对噪声敏感,可能引入噪声或异常值;计算成本高;未考虑类别关系
Kmeans-SMOTE	每个聚类单独使用 SMOTE;减少噪声和异常值影响;减少类内差异	效果依赖于聚类数选择;对初始聚类中心敏感;未考虑多数类信息
边界合成过采样 (Smote-Borderline)	重点生成边界样本,增强分类器对边界的学习;减少噪声影响	可能丢失全局信息;忽略非边界少数类样本;依赖边界区域定义;容易过拟合
GMM-SMOTE	对少数类样本针对性地过采样;样本数量合理;采用 Tomek's Links 数据清洗技术减少边界混淆	涉及到大量参数估计和迭代生成,计算复杂度;依赖 GMM 参数选择
随机重叠采样数据增强	方法简单、易于实现;计算成本低;无需额外信息;适用于各种数据集	噪声样本容易放大;数据质量不稳定;无法增加信息量;类别间关系被忽略
无参数化剪切翻转数据增强方法	计算成本低;实现简单;无需额外信息	生成样本多样性有限;数据增强效果提升不明显

SMOTE 方法通过生成少数类样本的合成数据来平衡数据分布,能够有效提升在不平衡数据上的分类器性能。但是,SMOTE 容易导致过拟合,忽略了多数类样本,对噪声敏感且计算成本高。Kmeans-SMOTE 改进了 SMOTE,引入 K 均值聚类以更精确地选择和生成合成样本,但仍受限于计算复杂度和噪声数据。Smote-Borderline 专注于在少数类和多数类边界生成合成样本,尽力减少过拟合风险,但效果依赖于边界实例的准确定义。其他方法如随机重叠数据增强、GMM 结合 SMOTE 及 Tomek's Links 清洗等则通过不同方式提升数据集质量,但也存在各自计算复杂度和适用性的挑战。无参数化剪切翻转数据增强方法虽然简单且计算成本低,但仅限于简单变换,难以直接解决类别不平衡问题。综合评价来看,各种算法针对数据不平衡问题提出了不同的解决方案,但是需要根据具体场景和数据分布特点进行选择。

2.2 模型生成方法

深度学习模型以其可以自动学习数据特征的优点,在图像分类、目标识别等领域已经取得了巨大成功。其中,生成对抗网络(Generative Adversarial Networks, GAN)和变分自编码器(Variational Auto Encoder, VAE)是近年来兴起的最具潜力的生成模型。GAN 由生成器和判别器组成。生成器试图生成逼真的数据样本,判别器则试图区分生成的样本和真实数据样本。两者通过对抗训练相互竞争,从而使生成器逐渐学习生成更逼真的样本,而判别器也逐渐变得更加精准。VAE 的网络结构主要包含隐变量编码部分和解码生成部分,模型的优化目标是尽可能使学习到的隐变量分布逼近标准正态分布,并且不断缩小生成样本和原始真实样本间的重构误差。因此,GAN 和 VAE 被广泛应用于样本不平衡研究中,但是传统的 GAN 和 VAE 仍然存在一些问题,需要在此基础上根据面临的不同问题单独进行改进,下面将介绍基于传统 GAN 和 VAE 的改进方法。

传统的生成式对抗网络(GAN)在实际应用中面临着训练不稳定、梯度消失等问题,可能导致图像失真。因此,传统的 GAN 训练过程较为困难,生成器和判别器很难同时达到稳定的收敛状态。为了克服传统 GAN 的缺点,文献[6]采用了深度卷积生成对抗网络(Deep Convolution Generative Adversarial Network, DCGAN)。与传统的 GAN 网络不同,DCGAN 采用深层卷积网络代替多层感知机,以增强模型对样本特征的挖掘能力,并使模型训练过程更加稳定。DCGAN 在生成和判别网络中均采用深度卷积网络结构,每层网络也采用了批归一化操作,以提高模型对特征的提取能力,而且引入遗传算法(Genetic Algorithm, GA)、Leaky ReLU 函数和 Tanh 函数来提高训练过程的稳定性。然而,采用卷积神经网络需要更加关注参数数量和计算成本,但 GA 算法中的参数,如种群个数、最大遗传数、交叉概率和变异概率等,仍需根据先验知识或人为经验进行设定,在生成样本质量方面还要继续突破 GAN 框架本身的局限性。文献[7]的关注点在卷积神经网络中,通过传统对抗网络生成与真实样本极其相似的样本后,将密集块与扩容卷积引入卷积神经网络中,从深度和广度两方面提升网络的学习能力,挖掘多类别数据中的细微差距,增强复杂数据的故障特征提取性能。文献[8]提出的自适应辅助分类器生成式对抗网络则通过衡量判别器与生成器的相对性能差异来自适应地调节生成器损失值,使训练收敛更快、生成数据质量更好。针对传统的对抗生成网络采用一种自适应的生成器损失函数,能够动态调节生成器和判别器的性能。文献[9]提出基于重要性自编码器的网络结构对原始数据进行增强,通过加权损失函数的方式平衡不同类别样本的重要性,令模型更加关注少数类别的学习。但是,该模型是以牺牲编码器的性能为代价来提高解码器的模型生成能力。为了能够在生成高质量样本的同时保证样本的多样性,文献[10]采用深度条件卷积 Wasserstein

对抗网络(Deep Conditional Wasserstein Generative Adversarial Network with Gradient Penalty, DCWGAN-GP)对多源域数据进行增强,以生成与多源域数据存在相似分布的辅助域。通过辅助域的加入,使训练域与未知目标域具有更大的分布相似性,可增加训练样本数量,提升训练样本的多样性,并通过对抗训练分布对齐方法缩小训练域之间的分布差异,实现训练域的特征域自适应。该模型将传统GAN中使用的(Jensen-Shannon divergence, JS)散度替换为Wasserstein距离,以保证生成数据和真实数据分布之间没有任何重叠,且能衡量生成数据与真实数据之间的差异性。但是,上述研究的故障准确率很大程度上依赖辅助域质量,并且有着很高的计算复杂度。随着VAE和GAN的广泛应用与不断改进,研究者们尝试将两者结合并提出了VAE-GAN。然而,最初的VAE-GAN模型只是将VAE和GAN进行简单连接,未能充分发挥两者的协同优势。文献[11]在此基础上提出样本增广模型VAE-WGAN(Variational Autoencoder-Wasserstein Generative Adversarial Networks),并对传统VAE-GAN的损失函数和模型训练两方面进行了改进。具体来说,其将损失函数分为编码损失、生成损失和判别损失3部分,并独立更新每个部分的网络,提高了损失函数设计的灵活性,使模型更好地适应不同的数据和应用场景。

VAE-WGAN模型主要由编码器、生成器(解码器)和判别器3部分组成。编码器和判别器分别属于VAE模块与WGAN模块,而生成器既是VAE中的解码器,又是WGAN中的生成器。模型中的VAE模块旨在最小化输入与输出之间的欧式距离,WGAN模块则通过采用Wasserstein距离度量代替JS散度来优化生成器参数,最小化生成损失,从而完成生成器的训练目标。

文献[11]在小样本条件下进行数据扩充后,在凯斯西储大学数据集上进行了测试,结果显示,在准确率、FID分数和LPIPS分数方面,VAE-WGAN模型均取得了优异表现。文献[12]提出一种基于距离约束的方法以进一步提高生成样本的质量,主要目的是降低生成样本和真实样本之间的差距,确保各样本间的类别区分合理,还要防止生成器从不同的真实样本中生成与真实样本极其相似的样本,从而增加样本的多样性。具体来说,首先计算真实样本类别之间的距离 D_{ij} 以及生成样本类别之间的距离 d_{ij} ,并最小化两者之间的差异以保证样本分布的相似性。然而,完全约束生成样本与真实样本的距离会导致生成样本缺乏多样性。因此,本文进一步放松了约束条件。具体公式如下:

$$L_d = (D_{ij}^2 - d_{ij}^2) + R \quad (2)$$

其中, R 是真实样本与生成样本同一类别之间相似度的正则项,通过允许两者存在一定的差异性以保证样本的多样性,从而提高模型的泛化能力。为了自适应确定 R 值,首先计算真实样本每一批次不同类别的中心点 O 和 N ,

以及生成样本每一批次不同类别的中心点 o 和 n ,并约束生成样本不同类别中心间的距离不小于真实样本不同类别中心间的距离。具体公式如下:

$$R = O - N^2 - o - n^2 \quad (3)$$

最终,距离约束损失函数为:

$$L_1 = \frac{1}{uv} \sum_{i=1}^u \sum_{j=1}^v (D_{ij}^2 - d_{ij}^2) + O - N^2 - o - n^2 \quad (4)$$

其中, u, v 分别代表类别一和类别二的样本数。

传统GAN在生成高质量的样本后,如何提高分类器的准确性也是关键。考虑到传统的损失函数如交叉熵损失可能会导致模型过于关注多数类别,而针对少数类别的性能较差。针对上述问题,文献[13]提出基于焦点损失(Focal Loss, FL)和卷积神经网络(CNN)的FLCNN(Focal Loss and Convolutional Neural Network)样本分类模型,将焦点损失(FL)应用到卷积神经分类网络中。FL的加入能够让模型在训练时更加关注难分样本,通过降低易分类样本的权重和提高难分样本的权重来提高模型分类精度,但是容易发生拟合。文献[14]采用FL函数来修正模型训练的倾向性,以平衡正常状态数据和故障状态数据的比例,从而改善正常样本数量远大于故障样本数量的问题。文献[15]则将改进的DCGAN算法与双线性插值的上采样相结合进行样本生成。传统的DCGAN算法在进行转置卷积操作时容易出现棋盘格效应,因此设计了USCONV层以改善该问题,从而生成更逼真的样本,且减少了训练时间和资源消耗,简化了模型结构。不同的模型生成方法比较如表2所示。

Table 2 Comparison of model generation methods

表2 模型生成方法比较

方法	优点
深度卷积生成对抗网络	提高样本特征的挖掘能力;增强了特征提取能力;提高训练稳定性
自适应辅助分类器生成式对抗网络	自适应调节生成器损失值,使训练器收敛更快;动态调整生成器与判别器的性能
深度条件卷积Wasserstein对抗网络	保证生成数据和真实数据分布没有重叠,可以衡量生成数据与真实数据之间的差异性
重要性加权自编码器	加权损失函数平衡不同类别样本的重要性,加强对少数类别的学习
FL-CNN模型	降低易分类样本权重,提高难分样本权重
深度卷积生成对抗网络	设计USCONV层缓解棋盘格效应;改善过拟合问题

3 变工况下的迁移学习

现实应用中轴承的运行环境是复杂多变的,且很难进行高度的复刻和模拟。迁移学习在目标域样本稀少而相关领域样本数充足的情况下有很大优势,对源域和目标域的要求较低,在训练过程中只需较少数据即可实现对轴承故障的准确诊断。迁移学习按照学习技术方法可分为基

于样本的迁移学习、基于特征的迁移学习与基于参数的迁移学习。

3.1 基于样本的迁移学习

基于样本的迁移学习核心思想是找到源领域和目标领域之间的相似性或相关性样本,并将这些样本用于目标领域的学习任务中。

在多源域情况下,文献[16]提出一种基于可迁移注意力机制和动态卷积网络的方法。该机制通过一个可迁移计算模块实现,该模块包含 K 个尺度领域判别器,每个判别器对应一个源域。通过将每个源域与目标域配对,判别器评估特征来源的难易程度,从而确定最适合迁移的源域,并根据评估结果分配相应权重。这些权重用于对多尺度特征进行加权融合,生成高级抽象特征,并将其传递给判别器和分类器,以最小化损失并达到最佳效果。然而,当多源域之间存在较大差异时,应更关注如何有效地减少源域与目标域之间的差异。文献[17]提出一种采用深度迁移学习与自适应加权的滚动轴承故障诊断方法,该方法利用深度卷积神经网络将样本映射到高维空间,再通过加权领域鉴别器对样本进行自适应加权。通过特征空间的对抗训练,增大源域样本和目标域样本的相似性。最终根据源域和目标域相似性的大小对目标域的额外故障进行状态样本标记。

可迁移的注意力机制和动态卷积网络具有多源域适应性,通过 K 个尺度领域判别器使每个源域与目标域配对,灵活处理多个源域并动态分配权重,以提升特征融合质量;利用多尺度特征的加权融合获取更高级的抽象特征,提高模型的泛化能力。然而,如果多源域之间存在较大差异,该方法在降低源域和目标域之间差异方面可能效果不佳。同时,由于需要 K 个领域判别器进行多尺度特征计算和融合,增加了计算复杂度和训练时间。基于深度迁

移学习与自适应加权的滚动轴承故障诊断方法利用深度卷积神经网络将样本映射到高维空间,提取更具代表性的特征,通过加权领域鉴别器对样本进行自适应加权,使模型能更好地调整源域和目标域样本的权重,通过特征空间的对抗训练增大源域和目标域样本的相似性,提高模型在目标域上的泛化能力。然而,该方法依赖于源域和目标域之间的相似性对目标域进行额外的故障状态样本标记,可能需要额外的标注工作,且对抗训练和自适应加权过程复杂,增加了训练难度和计算成本。

3.2 基于特征的迁移学习

基于特征的迁移学习方法应用较广,其核心思想是通过在源领域和目标领域之间共享或转移特征信息来提升目标领域的学习性能。在基于特征的迁移学习中,领域自适应方法被广泛应用,其核心思想是利用源领域已有的知识来帮助模型适应目标领域。常用的领域自适应方法包括域间对抗训练、领域间迁移学习、领域间对齐。

当工况之间差异较大时,文献[18]提出基于卷积注意力的特征迁移学习方法。该方法由卷积多头自注意力特征提取网络和域自适应迁移学习网络组成。首先,利用卷积多头自注意力特征提取网络提取高维特征,并通过分布差异度量函数构造特征迁移损失函数,进而学习域自适应网络的参数集,以实现不同分布样本在公共特征空间内的最大化同分布。在预测目标域的伪类标签时,使用相似度量函数计算源域样本和目标域样本的相似度,并选择相似度最高的源域高维特征生成对应的类别伪标签。之后,将上述两种损失函数合并为卷积注意力特征迁移学习的联合损失函数,通过随机梯度下降法将联合损失函数训练至收敛,从而实现工况的迁移。然而,该方法仅考虑了公共特征,缺乏对每个源域和目标域相似性的比较。联合损失函数如下:

$$\Gamma(\theta) = \rho l(\theta) + \Phi(\theta) = \rho \varphi(f_s^m(\theta), f_r^l(\theta)) - \sum_l \log \frac{\exp(\zeta(k, f_r^l(\theta)))}{\sum_{k=1}^K \exp(\zeta(k, f_r^l(\theta)))} \quad (5)$$

其中, $\rho l(\theta)$ 表示域适应损失部分,用于衡量源域和目标域特征之间的差异; $\Phi(\theta)$ 表示分类损失部分,用于衡量模型在目标域上的分类性能; $f_s^m(\theta)$ 、 $f_r^l(\theta)$ 分别表示源域与目标域中第 M 层和第 L 层高维特征; φ 是一个函数,用于计算源域特征和目标域特征之间的差异; $\sum_{l=1}^L \log \frac{\exp(\zeta(k, f_r^l(\theta)))}{\sum_{k=1}^K \exp(\zeta(k, f_r^l(\theta)))}$ 表示分类损失的部分,通过对数似然损失进行计算; ζ 是一个函数,用于计算特征 $f_r^l(\theta)$ 与类 K 的匹配程度。

为了充分学习域不变特征,从而实现源域与目标域的对齐,文献[19]采用基于GCN(Graph Convolutional Network)的多源变工况故障诊断方法,取多个分类器的平均值为目标域样本的状态识别结果。该网络采用共享特征

提取器和特定域特征提取器,共享特征提取器将所有域投射至公共的特征空间,然后针对每组源域—目标域数据对,分别利用各自的特定域提取器将其投影至特定的特征空间,以进行更好的迁移。

在实际应用中,由于目标域标签数量较少,域适应轴承故障诊断方法的准确率通常偏低。文献[20]提出的多层域适应的无标签数据故障诊断方法在特征提取阶段,首先使用多层最大均值差异算法(Multilayer Maximum Mean Discrepancy, MK-MMD)对输入特征进行差异计算,并采用伪标签策略解决目标域无标签导致模型无法训练的问题。之后,通过卷积网络充分提取域不变特征。在反向传播过程中,通过计算损失值并使用SGD(Stochastic Gradient Descent)优化器对网络模型参数进行充分更新。当网络损失值不再下降时结束训练,从而实现域自适应。

最大均值差异算法用于比较两个分布是否相同,通常利用核方法来计算源域和目标域之间的差异。基本原理是将数据通过核函数映射到一个高维的再生核希尔伯特空间,然后在该空间中计算两个分布的均值,并求其差异的范数。具体公式为:

$$\text{MMD}^2(P, Q) = \mathbb{E}_{x, x' \sim P}[k(x, x')] + \mathbb{E}_{y, y' \sim Q}[k(y, y')] - 2\mathbb{E}_{x \sim P, y \sim Q}[k(x, y)] \quad (6)$$

其中,参数 P 表示源域的分布, Q 表示目标域的分布, $\mathbb{E}_{x, x' \sim P}[k(x, x')]$ 表示计算源域内样本核函数值的期望, $\mathbb{E}_{y, y' \sim Q}[k(y, y')]$ 表示计算目标域内样本核函数值的期望, $\mathbb{E}_{x \sim P, y \sim Q}[k(x, y)]$ 表示计算源域分布和目标域分布中跨分布样本的核函数值的期望。

多层最大均值差异算法是对传统最大均值差异(Maximum Mean Discrepancy, MMD)算法的一种扩展,旨在更有效地衡量高维数据或复杂数据分布之间的差异。其结合了多层特征表示和核方法,以捕捉更细粒度的分布差异。在计算过程中,在深度特征提取阶段,第1层网络的特征表示为:

$$\begin{aligned} h_x^l &= \{h_x^l(x_1), h_x^l(x_2), \dots, h_x^l(x_m)\} \\ h_y^l &= \{h_y^l(y_1), h_y^l(y_2), \dots, h_y^l(y_n)\} \end{aligned} \quad (7)$$

其中, x 和 y 分别代表给出的两个样本集。再分别计算该层特征的 MMD:

$$\begin{aligned} \text{MMD}_i^2(h_x^l, h_y^l) &= \frac{1}{m^2} \sum_{i,j} k(h_x^l(x_i), h_x^l(x_j)) + \\ &\frac{1}{n^2} \sum_{i,j} k(h_y^l(y_i), h_y^l(y_j)) - \frac{2}{mn} \sum_{i,j} k \end{aligned} \quad (8)$$

其中, k 是选定的核函数,如高斯核。在计算完单层 MMD 值之后,将各层的 MMD 值加权求和,得到最终的多层 MMD 值:

$$\text{MMD}2(X, Y) = \sum_{l=1}^L \alpha_l \text{MMD}_i^2(h_x^l, h_y^l) \quad (9)$$

其中, α_l 是第1层的权重,通常通过交叉验证或其他优化方法确定。多层最大均值差异算法可以更有效地减少源域和目标域之间的分布差异,提高模型的泛化能力。

伪标签策略常用于目标域数据无标签的情况下,其核心思想是将模型对无标签数据的预测结果作为标签,将无标签数据转化为有标签数据参与训练。首先,用源域带标签的数据训练初始模型;其次,用该模型针对目标域的无标签数据生成伪标签,再从中筛选高置信度的伪标签;再次,将筛选后的伪标签与目标域数据结合,形成新的训练集;最后,利用新的训练集重新训练模型,并迭代上述过程,不断更新伪标签和模型,从而提高模型在目标域的适应性和整体性能。

$$\text{LMMD}^2(P, Q | \mathcal{R}) = \mathbb{E}_{x, x' \sim P, x \in \mathcal{R}}[k(x, x')] + \mathbb{E}_{y, y' \sim Q, y \in \mathcal{R}}[k(y, y')] - 2\mathbb{E}_{x \sim P, y \sim Q, x \in \mathcal{R}, y \in \mathcal{R}}[k(x, y)] \quad (10)$$

上述公式限定在某个局部区域 \mathcal{R} 内计算分布差异。参数 P 表示源域的分布, Q 表示目标域的分布, \mathcal{R} 表示局部

文献[21]中迁移堆栈自编码器的轴承故障诊断方法主要利用堆栈自编码器的多分类网络结构进行特征提取,然后采用多核最大均值差异作为评价源域和目标域的距离指标,实现域不变特征提取并进行迁移学习,成功解决了不同工况下轴承故障智能诊断的问题。当面临故障样本稀缺、模态单一和训练及测试数据分布不同的问题时,文献[22]采用深度多模态融合迁移学习技术,将 CNN 与多模态融合迁移学习技术相结合进行故障诊断。其基于多个或多类不同类型或相同类型的信息数据,通过特征抽取等空间变化方法,将同构或异构信息转换为一致性的表示,之后进行信息的有效融合,以最大均值差异为度量准则,从而最小化源域和目标域的差异。文献[23]针对传统轴承故障诊断需要人为先验知识的问题,提出基于小波包迁移学习的轴承故障诊断方法。通过对源域数据和目标域数据进行4层小波包分解,从而提取16个不同尺度和频率的轴承故障信号,确保了信息的完整性。之后,利用多核最大均值差异(Multi-Kernel Maximum Mean Discrepancy, MK-MMD)来度量源域和目标域之间的边缘分布距离,以减少两域之间特征分布的差异。文献[24]为解决源域与目标域特征分布不同的问题,在损失函数中引入了多核最大均值差异(MK-MMD)和联合最大均值差异(Joint Maximum Mean Discrepancy, JMMD),用于构造域适应模块。这些度量方法用于衡量源域和目标域特征分布的差异,并将结果添加到损失函数中,从而构建具有域适应能力的深度迁移网络。通过损失函数的反向传播来减少源域和目标域特征分布的差异,实现模型的迁移。基于特征迁移学习的领域自适应技术已经在故障诊断领域得到了广泛应用,但多数方法仅关注全局域分布,而忽视了同类别下的子域分布。此外,域不变特征质量易受强噪声影响,导致诊断精度大幅下降。文献[25]在此基础上提出一种基于自注意力子域自适应对抗网络的故障诊断方法,通过融合卷积注意力模块提取源域与目标域振动信号中与故障相关的域不变特征,然后通过域判别器与特征提取器的对抗学习,缩小源域与目标域的全局分布差异。在同类别子域分布中,利用子域自适应层中的局部最大均值差异函数(Local Maximum Mean Discrepancy, LMMD)减小源域与目标域相关子类的概率分布,从而提高数据的可迁移性。

局部最大均值差异(LMMD)将 MMD 的思想应用到局部区域,用于比较两个分布在特定区域内的差异程度。LMMD 可以用来识别局部区域内的分布差异,而不是整体上的分布差异。这在处理复杂数据集和高维数据时尤其有用,因为整体分布的差异可能被局部区域的差异掩盖。LMMD 公式表示为:

区域,该区域可以通过某些特定条件或区域选择方法来确定。 x, x' 与 y, y' 分别代表从源域和目标域中抽取的样本。

文献[26]提出构建领域共享的局部特征收缩网络(CNN-SN)的方法,通过该网络能够从多种工况的故障样本中提取有效的故障特征。同时引入最大最小化分类器差异的对抗学习策略,以进一步减小不同域特征的条件分布差异,实现不同域相同类别的子领域对齐。文献[27]通过在深度残差收缩网络中加入领域适配层,构建了具备降噪与适配能力的深度残差收缩迁移网络,通过边缘分布适配对齐两域特征分布,减小了工况变化带来的分布差异。文献[28]提出一种基于多尺度分层交替迁移学习的小样本轴承跨域故障诊断模型,采用分层交替迁移学习算法来处理域位移问题,并利用 Coral 和 LMMD 算法的特性进行互补。在卷积的第一层中添加 DeepCoral 损失函数,以计算不同域的协方差,在全连接层中则引入 LMMD 和交叉熵损失函数。在反向传播过程中,依次计算这些损失函数并交替更新网络参数,从而增强迁移学习效果。

DeepCORAL (Deep Canonical Correlation Analysis with CORAL) 的核心思想是通过最小化源域和目标域特征第二阶统计量(协方差矩阵)差异的方式实现域适应。在对齐源域和目标域特征时,DeepCORAL 通过最小化以下损失函数实现特征对齐:

$$\mathcal{L}_{CORAL} = \frac{1}{4d^2} \|C_s - C_t\|_F^2 \quad (11)$$

其中, C_s, C_t 分别表示源域和目标域的协方差矩阵, $\|\cdot\|_F$ 表示 Frobenius 范数, d 表示特征维度。协方差矩阵计算方式如下:

$$\begin{aligned} C_s &= \frac{1}{n_s - 1} \left(X_s^T X_s - \frac{1}{n_s} (1^T X_s)^T (1^T X_s) \right) \\ C_t &= \frac{1}{n_t - 1} \left(X_t^T X_t - \frac{1}{n_t} (1^T X_t)^T (1^T X_t) \right) \end{aligned} \quad (12)$$

其中, n_s, n_t 分别是源域和目标域的样本数量, 1 是全 1 向量。

文献[29]提出一种内对抗指导的无监督多域适配网络,该网络主要由内对抗模块和多子网协同决策模块组成。内对抗模块计算多源域对抗损失,用于提取多源域和目标域之间的共性特征。多子网协同决策模块用于计算置信分数,辅助多子网分类器作出最佳的融合决策,以提升协同故障诊断的准确率。文献[30]将残差网络和迁移学习相结合构建迁移学习故障诊断模型,从而对滚动轴承故障进行快速诊断,极大地缩短了诊断时间。迁移方法比较如表 3 所示,跨域诊断任务实验数据如表 4 所示。

3.3 基于参数的迁移学习

基于参数的迁移学习需要在源域上进行训练,训练完成后根据目标域中带标签的样本进行参数微调。其只需通过微调或调整部分参数即可适应目标领域,而无需重新训练整个模型,从而节省了大量的计算资源和时间,且相比其他方法难度更低。但是,基于参数的迁移学习需要目标域中含有部分带标签数据,这也是该方法存在的一个严重弊端。如果目标域中携带标签的数据较少,如何高效地

Table 3 Comparison of migration methods

表 3 迁移方法比较

方法	优点
卷积注意力特征迁移学习	多头自注意力机制提取到不同故障信息;结合特征迁移损失函数和分类损失函数来构造 C A F T L 的联合损失函数,提高了分类性能,具有有效的公共特征空间迁移策略
多源图卷积网络的变工况故障诊断	充分利用多源域知识,弥补了单源域学习的局限性;采用共享特征提取器和特定特征提取器进行充分迁移
多层域适应的无标签数据故障诊断	采用小波包分解与重构对原始振动信号进行特征优化,避免信号冗余,并减少特征遗失;将多层域适应和伪标签相结合,解决了目标域无标签问题
迁移堆栈自编码器	改善标注监测数据缺少问题;防止过拟合
自注意力子域自适应对抗网络	重点关注同类别下的子域分布;结合对抗网络和子域自适应模块,减小全局域和局部域边缘分布差异
内对抗指导的无监督多域适配网络	构建多组相互独立的源域—目标域自适应子网,以提供充足且多样化的诊断信息;构造一个内对抗模块以计算多源域对抗损失;利用多组源域—目标域的对抗损失和分布差异损失计算置信分数

利用这些数据对参数进行调整则是一个待解决的问题。此外,如果目标域中缺乏带标签的数据,则需要给目标域中的数据赋予正确的标签进行模型参数的微调。

针对多工况差异较大问题,文献[31]提出基于迁移 QCNN (Quadratic Convolutional Neural Network) 的孪生网络,先利用 QCNN 网络的提取能力进行预训练,再将得到的参数迁移到孪生网络的主干网络中,使网络模型一开始就具有判别性强的初始参数。采用孪生网络本身成对训练和共享权重提取故障共同特征的方式,可以改善工况数据不平衡和噪声问题。但是,将故障样本利用小波变换、时频变换等信号处理方法进行故障特征提取后,可能会造成故障信息的损失。针对此问题,文献[32]提出基于一维卷积注意力门控循环网络和迁移学习的轴承故障诊断方法,通过源域进行训练,再将训练好模型中的权重参数迁移到目标域,并添加一个新的 dense 层以根据目标域的少量样本进行微调。主要目的是对迁移过来的特征提取层进行冻结,只通过微调 dense 层的方式完成模型参数迁移。文献[33]针对故障信息收集困难的问题,采用伪标签策略对模型进行训练,并在模型参数迁移后进行微调。将预训练的参数从一个深度神经网络模型迁移到 ResNet18 网络中,再使用源域和目标域的伪标签进行训练,并通过调整不同的学习率来微调参数,从而实现参数迁移。

基于迁移的孪生网络通过预训练 QCNN 网络来获取预训练参数,之后迁移到 QCNN 作为子网络的孪生网络中。其具有初始参数判别性强的优势,能够改善工况数据不平衡和噪声问题。信号处理方法可能会导致故障信息

Table 4 Cross domain diagnostic task experimental data

表4 跨域诊断任务实验数据

方法	凯斯西储大学数据集				跨域诊断任务			平均 准确率/%
	工况类型							
深度迁移学习	A	B	C	D	A1→B	A1→C	A1→D	90.57
	0hp	1hp	2hp	3hp	A2→B	A2→C	A2→D	
					A3→B	A3→C	A3→D	
卷积注意力特征迁移学习	A	B	C	D	A→C	B→C		97.40
	1hp	3hp	2hp	6 000 lbs (径向载荷)	A→D	B→D		
多源变工况	A	B	C		B、C→A	A、C→B	A、B→C	99.58
深度多模态迁移学习	A	B	C	D	A→D	A+B→C+D		97.80
	0hp	1hp	2hp	3hp	B→C	C+D→A+B		
小波包迁移学习	A	B	C	D	A→B	A→D	B→C	99.58
	0hp	1hp	2hp	3hp	A→C	B→A	A→D	
无监督域适应	A	B	C		A→B	B→A	C→A	97.65
					A→C	B→C	C→B	
多尺度分层交替迁移学习	A	B	C		A→B	B→A	C→A	94.17
	1hp	2hp	3hp		A→C	B→C	C→B	

损失,需要注意提取的特征是否完整。基于一维卷积注意力门控循环网络和迁移学习的轴承故障诊断方法通过训练源域模型来获取参数进而迁移到目标域,并通过微调以获得更好的模型迁移效果,从而降低迁移成本,但需要注意特征提取层的冻结对模型的影响。采用伪标签策略的方法在故障信息收集困难时表现突出,通过迁移预训练参数和微调来提升模型性能,但需要对源域和目标域的伪标签训练数据进行处理,以避免出现过拟合问题。

4 未来研究与展望

4.1 样本不平衡

本文整理了生成对抗网络(GAN)与变分自编码器(VAE)的最新研究进展,针对其初始模型的不足,已有文献提出了多种有效的改进方案,推动这两种模型在该领域的广泛应用与快速发展。然而,近年来,扩散模型作为一种新兴的生成模型,在GAN和VAE的基础上取得了显著突破,并因其卓越的性能而受到广泛关注。因此,未来的研究可以重点关注扩散模型的以下几个方面:

(1) 数据生成。扩散模型在图像生成方面表现出了显著优势,尤其是在生成高质量和高分辨率图像方面,能够生成细节更丰富、逼真的图像。例如,DDPM(Denoising Diffusion Probabilistic Models)和 Score-Based Generative Models等扩散模型在图像生成任务中已取得了卓越成果。然而,在轴承故障诊断领域,仍需要根据具体需求从扩散模型中挑选适合的模型来生成与轴承相关的数据,而不仅仅局限于图像和视频数据。

(2) 自适应扩散策略。在当前的扩散模型中,噪声的

强度通常是预设的,并且在整个生成过程中保持不变。这种静态的噪声控制可能导致在生成不同阶段的图像时,噪声水平不适当当前的数据质量要求,从而影响生成结果的质量。因此,可以设计一个能够实时监控生成过程的机制,根据生成数据的实时反馈动态调整噪声强度。例如,可以引入一个噪声控制模块,该模块通过评估生成样本的质量指标(如图像的清晰度、细节丰富度等),自动调整噪声强度以优化生成效果,或者在扩散模型的训练和生成过程中,逐渐减小噪声强度。初期可使用较高的噪声强度以增加样本的多样性,随着生成过程的推进,再逐步减小噪声以细化生成的细节。

(3) 扩散模型与其他生成模型的结合。扩散模型、生成对抗网络(GAN)和变分自编码器(VAE)各具优势和不足,未来可以探索将扩散模型与这两种模型相结合,以充分利用各自的优势,进一步提升样本生成的质量和效率。例如,可以在扩散模型生成的基础上,使用GAN进行样本的进一步优化,以提高生成样本的细节和真实性,或者结合VAE的稳定性,提升生成样本的多样性和一致性。

4.2 变工况下的迁移学习

在迁移学习部分,本文讨论的方法主要建立在源域与目标域类别一致性的基础上,即目标域中的类别是源域中已有的故障类型。然而,在实际应用中,源域和目标域的数据分布可能存在显著差异。现实中的故障种类繁多且复杂,这种数据分布差异可能导致模型在目标域上的性能下降,从而影响对目标域故障的准确识别和诊断。因此,未来的研究需要更加关注开放集的差异问题,以应对源域和目标域之间类别不一致和数据分布变化带来的挑战。在以下3个方面仍需作进一步研究:

(1)新故障类型的检测与识别。可以利用自编码器(Autoencoder)等重建模型来检测目标域中的新故障类型。在训练阶段,自编码器学习源域数据的重建模式,而在测试阶段,新故障类型的样本通常会生成较高的重建误差,这一异常误差可用于识别未知故障。此外,还可以应用异常检测算法在特征空间中识别异常样本。通过分析样本在特征空间中的位置,能够检测出与源域数据显著不同的异常样本,从而有效识别潜在的新故障类型。

(2)新故障类型的特征学习。在遇到新的故障类型时,可以采用增量学习技术,使模型能够在遇到新故障类型时,逐步更新其参数,而不需要重新训练整个模型。增量学习技术能够有效地利用目标域中的新样本,实现模型的动态更新,使其在面对新故障类型时保持高效的适应能力。该过程不仅提升了模型对新故障的识别能力,而且避免了重新训练模型所需的高计算开销,从而提高了故障诊断系统的灵活性和实用性。

(3)开放集识别技术优化。针对未知故障类型的识别,可以聚焦于开放集分类器的优化和置信度估计的改进,探索如何更准确地将样本分类为已知类别或未知类别,并提高对新故障类型的检测能力。同时,还可以研究新的置信度计算方式和阈值调整策略,以便在出现新故障类型时,模型能够更早地识别并采取相应行动。

参考文献:

- [1] DOUZAS G, BACAO F, LAST F. Improving imbalanced learning through a heuristic oversampling method based on k-means and SMOTE[J]. Information Sciences, 2018, 465: 1-20.
- [2] JIN J H, DONG Z S, LI L J. Bearing unbalance fault diagnosis based on over-sampling and time-frequency fusion [J]. Journal of Taiyuan University of Science and Technology, 2023, 44(2): 142-147, 154.
靳建华,董增寿,李丽君.基于过采样与时频融合的轴承不平衡故障诊断[J].太原科技大学学报,2023,44(2):142-147,154.
- [3] CHEN X L, SUN Y F, LI C, et al. Stable anti-noise fault diagnosis of rolling bearing based on CNN-BiLSTM [J]. Journal of Jilin University (Engineering and Technology Edition), 2022, 52(2): 296-309.
陈晓雷,孙永峰,李策,等.基于卷积神经网络和双向长短期记忆的稳定抗噪声滚动轴承故障诊断[J].吉林大学学报(工学版),2022,52(2):296-309.
- [4] WANG Z Y, LIU T, WANG T X, et al. Application of unbalance technique in bearing fault diagnosis [J]. Machinery & Electronics, 2021, 39(6): 29-34.
王振亚,刘韬,王廷轩,等.不平衡技术在轴承故障诊断中的应用[J].机械与电子,2021,39(6):29-34.
- [5] WU W Y, CHEN J L, LIU S, et al. Intelligent fault diagnosis method based on unsupervised feature representation deep Q-learning [J]. Journal of Central South University (Natural Science Edition), 2022, 53(5): 1750-1759.
乌文扬,陈景龙,刘莘,等.基于无监督特征表示深度Q学习的智能故障诊断方法[J].中南大学学报(自然科学版),2022,53(5):1750-1759.
- [6] SHI J, HU Y J, WANG S, et al. DCGAN combined with CNN to diagnose rolling bearing faults with unbalanced small samples [J]. Noise and Vibration Control, 2022, 42(6): 130-136, 142.
施杰,胡益嘉,王森,等.DCGAN结合CNN诊断不平衡小样本的滚动轴承故障[J].噪声与振动控制,2022,42(6):130-136,142.
- [7] GUO W, XING X S. Intelligent fault diagnosis of bearings with few samples based on an improved convolutional generative adversarial network [J]. China Mechanical Engineering, 2022, 33(19): 2347-2355.
郭伟,邢晓松.基于改进卷积生成对抗网络的少样本轴承智能诊断方法[J].中国机械工程,2022,33(19):2347-2355.
- [8] YANG G Y, LIU L, XI C B. Sample generation model and bearing fault diagnosis of adaptive auxiliary classifier generative adversarial network [J]. China Mechanical Engineering, 2022, 33(13): 1613-1621.
杨光友,刘浪,刁晨博.自适应辅助分类器生成式对抗网络样本生成模型及轴承故障诊断[J].中国机械工程,2022,33(13):1613-1621.
- [9] LI M N, LI K, WU C. Research on bearing fault diagnosis based on IWAE unbalanced dataset [J]. Journal of Mechanical Strength, 2023, 45(3): 569-575.
李梦男,李琨,吴聪.基于IWAE的不平衡数据集下轴承故障诊断研究[J].机械强度,2023,45(3):569-575.
- [10] XU N F, PENG Y J, ZHANG Q H. Cross domain fault diagnosis of bearings based on data augmentation and domain generalization [J]. Machine Tool & Hydraulics, 2024, 52(16): 183-193.
徐宁富,彭云建,张清华.基于数据增强与领域泛化的轴承跨域故障诊断[J].机床与液压,2024,52(16):183-193.
- [11] JIANG F, SONG H Y, SHEN X, et al. Fault diagnosis method of mine hoist main bearing with small sample based on VAE-WGAN [J/OL]. Coal Science and Technology, 2024-01-22. <https://www.mtkxj.com.cn/article/doi/10.12438/est.2023-1503>.
江帆,宋泓炎,沈熙,等.基于VAE-WGAN的矿井提升机主轴承小样本故障诊断方法[J/OL].煤炭科学技术,2024-01-22. <https://www.mtkxj.com.cn/article/doi/10.12438/est.2023-1503>.
- [12] LI K, HE J G, SU L, et al. Fault diagnosis method for rolling bearing based on CAE-GAN [J]. Journal of Vibration and Shock, 2023, 42(23): 65-70, 86.
李可,何坚光,宿磊,等.基于CAE-GAN的滚动轴承故障诊断方法[J].振动与冲击,2023,42(23):65-70,86.
- [13] ZHANG Y H, ZHANG Z Y, ZHAO X P, et al. Bearing fault diagnosis method based on VAE-GAN and FLCNN unbalanced samples [J]. Journal of Vibration and Shock, 2022, 41(9): 199-209.
张永宏,张中洋,赵晓平,等.基于VAE-GAN和FLCNN的不均衡样本轴承故障诊断方法[J].振动与冲击,2022,41(9):199-209.
- [14] YANG Z L, WU F Y, CHEN H X. Fault diagnosis of rotating machinery based on improved deep residual shrinkage network [J]. Journal of Mechanical & Electrical Engineering, 2023, 40(3): 344-352.
杨正理,吴馥云,陈海霞.基于改进深度残差收缩网络的旋转机械故障诊断[J].机电工程,2023,40(3):344-352.
- [15] LIU Y Q, CAI H Y, LI W K, et al. DCGAN diagnostic method for bearing faults under small sample conditions [J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(4): 817-823, 836.
柳雅倩,蔡浩原,李文宽,等.小样本条件下轴承故障的DCGAN诊断方法[J].振动、测试与诊断,2023,43(4):817-823,836.
- [16] WANG Y W, ZHU J, SHI Y W, et al. Cross condition fault diagnosis method for rolling bearings based on transferable attention and dynamic convolution [J]. Bearing, 2024(2): 82-88.
王煜伟,朱静,史曜炜,等.基于可迁移注意力和动态卷积的滚动轴承跨工况故障诊断方法[J].轴承,2024(2):82-88.
- [17] JIA F, LI S H, SHEN J J, et al. Rolling bearing fault diagnosis using

- deep transfer learning and adaptive weighting [J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 1-10.
贾峰,李世豪,沈建军,等. 采用深度迁移学习与自适应加权的滚动轴承故障诊断[J]. 西安交通大学学报, 2022, 56(8): 1-10.
- [18] ZOU J. Rolling bearing fault diagnosis based on convolutional attention feature transfer learning [J]. Computer Measurement and Control, 2024, 32(1): 23-29.
邹建. 基于卷积注意力特征迁移学习的滚动轴承故障诊断[J]. 计算机测量与控制, 2024, 32(1): 23-29.
- [19] XIE F Y, WANG L L, SONG M H, et al. Multi source variable working condition rolling bearing fault diagnosis based on GCN [J]. Journal of Railway Science and Engineering, 2024, 21(5): 2109-2118.
谢锋云,王玲岚,宋明桦,等. 基于GCN的多源变工况滚动轴承故障诊断[J]. 铁道科学与工程学报, 2024, 21(5): 2109-2118.
- [20] WANG J H, LIU R, CAO J. A fault diagnosis method for unlabeled data based on multi-layer domain adaptation [J]. Journal of Beijing University of Aeronautics and Astronautics, 2025, 51(4): 1185-1194.
王进花,刘瑞,曹洁. 基于多层域适应的无标签数据故障诊断方法[J]. 北京航空航天大学学报, 2025, 51(4): 1185-1194.
- [21] JIA M X, HAN B K, WANG J R, et al. Bearing fault diagnosis method based on transfer learning and stacked auto-encoders [J]. Noise and Vibration Control, 2021, 41(6): 84-90.
贾美霞,韩宝坤,王金瑞,等. 基于迁移堆栈自编码器的轴承故障诊断方法[J]. 噪声与振动控制, 2021, 41(6): 84-90.
- [22] GAO L P, LEI W P, CAO Y L, et al. Research on deep multimodal transfer learning in bearing fault diagnosis [J]. Machinery Design & Manufacture, 2024(4): 145-148, 153.
高丽鹏,雷文平,曹亚磊,等. 深度多模态迁移学习在轴承故障诊断中的研究[J]. 机械设计与制造, 2024(4): 145-148, 153.
- [23] GUO C Q, LI S S, HUANG H, et al. Research on bearing fault diagnosis method based on wavelet packet transfer learning [J]. Microcomputer Applications, 2024, 40(1): 131-133.
郭传清,李申申,黄璜,等. 基于小波包迁移学习的轴承故障诊断方法研究[J]. 微型电脑应用, 2024, 40(1): 131-133.
- [24] MENG D Q, XU J Y, YUAN J P, et al. Fault diagnosis of rolling bearings based on deep feature extraction and transfer learning [J]. Equipment Manufacturing Technology, 2023(6): 176-179, 200.
孟德乾,徐军杨,袁建平,等. 基于深度特征提取与迁移学习的滚动轴承故障诊断[J]. 装备制造技术, 2023(6): 176-179, 200.
- [25] WANG C, TIAN B, LI Z R, et al. Bearing fault diagnosis method based on self attention subdomain adaptive adversarial network [J]. Chinese Journal of Ship Research, 2023, 18(5): 260-268.
王超,田波,李子睿,等. 基于自注意力子域自适应对抗网络的轴承变工况故障诊断方法[J]. 中国舰船研究, 2023, 18(5): 260-268.
- [26] CHEN P, YUAN Y P, MA J Y, et al. Rolling bearing fault diagnosis based on CNN-SN and unsupervised domain adaptation [J]. Bearing, 2025(2): 93-101.
陈攀,袁逸萍,马军岩,等. 基于CNN-SN和无监督域适应的滚动轴承故障诊断[J]. 轴承, 2025(2): 93-101.
- [27] CHEN R X, ZHANG X, ZHU Y Q, et al. Fault diagnosis of rolling bearings under complex working conditions based on deep residual shrinkage transfer network [J]. Vibration and Shock, 2024, 43(3): 194-200.
陈仁祥,张晓,朱玉清,等. 基于深度残差收缩迁移网络的复杂工况下滚动轴承故障诊断[J]. 振动与冲击, 2024, 43(3): 194-200.
- [28] CAO J H, WEN C B. Small sample bearing cross domain fault diagnosis based on multi-scale hierarchical alternating transfer learning [J/OL]. Bearing, 2023-10-12. <https://kns.cnki.net/kcms/detail/41.1148.TH.20231011.0939.002.html>.
曹景浩,文传博. 基于多尺度分层交替迁移学习的小样本轴承跨域故障诊断[J/OL]. 轴承, 2023-10-12. <https://kns.cnki.net/kcms/detail/41.1148.TH.20231011.0939.002.html>.
- [29] SHAO H D, CHEN X K, CAO H R, et al. Bearing collaborative fault diagnosis guided by internal adversarial unsupervised multi domain adaptation network [J]. Scientia Sinica (Technologica), 2023, 53(7): 1229-1240.
邵海东,陈星恺,曹鸿儒,等. 内对抗指导无监督多域适配网络的轴承协同故障诊断[J]. 中国科学:技术科学, 2023, 53(7): 1229-1240.
- [30] LIU F, CHEN R W, XING K L, et al. Fast fault diagnosis algorithm for rolling bearings based on transfer learning and deep residual networks [J]. Vibration and Shock, 2022, 41(3): 154-164.
刘飞,陈仁文,邢凯玲,等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法[J]. 振动与冲击, 2022, 41(3): 154-164.
- [31] WANG J, ZHANG W T, YAN Z B, et al. Twin network bearing fault diagnosis method based on migration QCNN [J]. Computer Measurement & Control, 2024, 32(4): 1-7, 21.
王军,张维通,闫正兵,等. 基于迁移QCNN的孪生网络轴承故障诊断方法[J]. 计算机测量与控制, 2024, 32(4): 1-7, 21.
- [32] SHI J W, HOU L Q. Bearing fault diagnosis based on one dimensional convolutional attention gated recurrent network and transfer learning [J]. Journal of Vibration and Shock, 2023, 42(3): 159-164, 173.
石静雯,侯立群. 基于一维卷积注意力门控循环网络和迁移学习的轴承故障诊断[J]. 振动与冲击, 2023, 42(3): 159-164, 173.
- [33] SONG Y H, MA P, LI J J, et al. A semi supervised rolling bearing fault diagnosis model based on pseudo label deep learning [J]. Noise and Vibration Control, 2024, 44(2): 102-107, 184.
宋宇航,马萍,李建军,等. 基于伪标签深度学习的半监督滚动轴承故障诊断模型[J]. 噪声与振动控制, 2024, 44(2): 102-107, 184.

(责任编辑:黄健)