

DOI: 10.19650/j.cnki.cjsi.J2312259

基于信息融合子域适应的不同工况下 谐波减速器故障诊断方法*

康守强¹, 章炜东¹, 王玉静¹, 刘连胜^{2,3}, 孙宇林¹

(1. 哈尔滨理工大学模式识别与信息感知黑龙江省重点实验室 哈尔滨 150080;
2. 哈尔滨工业大学电子与信息工程学院 哈尔滨 150001; 3. 哈尔滨工业大学郑州研究院 郑州 450000)

摘要:针对工业机器人谐波减速器不同工况数据分布差异大,部分工况数据标签缺失以及单一传感器获取信息不全面,导致诊断准确率不高的问题,提出一种信息融合子域适应的不同工况下谐波减速器故障诊断方法。该方法将源域和目标域一维振动数据利用小波变换构建时频图;使用基于小波变换的图像融合方法整合多个传感器的时频信息并构建融合图像;提出多表示特征提取结构的改进残差网络以充分挖掘融合样本多表示特征,同时,在无监督场景下将源域和目标域融合样本的多表示特征进行子域适应处理,减小两域的各个子域间的分布差异,从而将知识从标签丰富的源域迁移到标签缺失的目标域,最终实现不同工况下谐波减速器的故障诊断。通过搭建工业机器人谐波减速器故障实验台并进行实测,所提方法在所有迁移任务中平均准确率可达98.8%,能够有效实现无监督场景中不同工况下谐波减速器的故障诊断。

关键词: 信息融合;不同工况;域适应;谐波减速器;故障诊断

中图分类号: TN911.7 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460.4099

A fault diagnosis method for harmonic reducers under different operating conditions based on information fusion subdomain adaptation

Kang Shouqiang¹, Zhang Weidong¹, Wang Yujing¹, Liu Liansheng^{2,3}, Sun Yulin¹

(1. Heilongjiang Province Key Laboratory of Pattern Recognition and Information Perception, Harbin University of Science and Technology, Harbin 150080, China; 2. School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150001, China; 3. Zhengzhou Research Institute, Harbin Institute of Technology, Zhengzhou 450000, China)

Abstract: In response to the significant variations in data distribution of industrial robot harmonic reducers under different operating conditions, the partial absence of data labels for certain conditions, and the incomplete information obtained from a single sensor, which together result in low diagnostic accuracy, a fault diagnosis method is proposed based on information fusion and subdomain adaptation for different operating conditions of harmonic reducers. Time-frequency graphs are constructed using wavelet transform on one-dimensional vibration data from source and target domains. Time-frequency information from multiple sensors is integrated using a wavelet transform-based image fusion method, and the fused image is created. To fully exploit the multi-representational features of the fused samples, an improved residual network with a multi-representation feature extraction structure is proposed. Simultaneously, in an unsupervised scenario, the multi-representation features of the fused samples from the source and target domains are subjected to subdomain adaptation, for reducing the distribution differences between subdomains of both domains. Transfer the knowledge from the label-rich source domain to the label-deficient target domain, and ultimately fault diagnosis of harmonic reducers can be achieved under different operating conditions. By establishing an experimental platform for the industrial robot harmonic reducers and conducting actual measurements, the proposed method can achieve an average accuracy of 98.8% for all transfer tasks, and effectively enable fault diagnosis of harmonic reducers under different operating conditions in an unsupervised scenario.

Keywords: information fusion; different working conditions; domain adaptation; harmonic reducer; fault diagnosis

收稿日期: 2023-12-08 Received Date: 2023-12-08

* 基金项目: 国家自然科学基金(52375533)、山东省自然科学基金(ZR2023ME057)、哈尔滨市制造业科技创新人才(2023CXRC0017)项目资助

0 引言

随着国家大力推进《中国制造 2025》,工业机器人作为工业自动化领域的重要组成部分,其需求量正逐年增多,应用领域也越来越广泛^[1]。谐波减速器是一种结构紧凑、质量轻而减速比大、传动精确的高性能减速器,作为工业机器人的“关节”,其正常运行对于工业机器人安全、精准、可靠地工作具有至关重要的作用^[2]。在实际的使用场景中,谐波减速器一般处于大负载和高扭矩的工作条件,易发生失效或者性能退化等问题,若其发生故障,将使工业机器人处于无法预知的运动状态,造成企业生产停滞,严重时甚至危及生产线工人的生命安全^[3]。同时,谐波减速器现实运行工况复杂多变,仅依靠单一传感器获取的运行信息往往有限且不同工况振动数据的分布存在较大差异,给谐波减速器的故障诊断带来困难。因此,避免单一传感器难以获取全面运行信息易造成“误诊”问题以及实现不同工况下谐波减速器的有效诊断,对于保证工业机器人的精准、健康运行,具有重要的现实意义^[4-5]。

近年来,随着人工智能的不断发展,深度学习方法凭借强大的自适应特征提取能力已经被广泛应用于谐波减速器等旋转机械诊断领域^[6]。文献[7]提出一种相位差频谱校正-互相关法,将获取的整周期数据用于谐波减速器故障诊断,取得了较好的诊断效果。文献[8]将机电电压信号用于卷积神经网络的训练,实现了对谐波减速器的故障诊断。文献[9]提出使用一维卷积神经网络提取时域信号特征进行故障诊断,利用工业机器人实际运行数据验证了所提方法的有效性。文献[10]将多尺度混合卷积神经网络用于工业机器人谐波减速器的故障诊断,准确率达到 97.08%。文献[11]先利用生成对抗网络生成数据,再结合多尺度卷积神经网络解决了谐波减速器不平衡数据的故障诊断问题。

深度学习方法为有效实现谐波减速器的故障诊断提供了思路,但在实际工业场景中,单一传感器获得的信息有限且容易受到传感器自身性能的影响,往往难以体现设备运行时的全部特征^[12]。同时,用于检测谐波减速器的传感器通常会随工业机器人关节运动而运动,这可能进一步造成单一传感器获得的数据不全面或不稳定^[13]。针对单个传感器无法提供较为全面的运行信息,容易造成错误诊断的问题,安装在不同位置的传感器可以获取到更完整全面的运行信息,因此利用多个传感器的数据进行故障诊断理论上能够有效降低“误诊”概率,提高诊断准确率^[14]。近年来,国内外众多学者在解决机械设备故障诊断问题时,将多传感器信息融合技术应用其中以提高诊断效果^[15]。文献[16]提出一种多传感器融合卷

积神经网络的方法,将用于监测航空发动机轴承的多个传感器一维数据输入到 1D-CNN 中进行故障诊断,获得较好的诊断效果。文献[17]将齿轮箱不同位置的传感器信号同时作为网络输入,并设计了一种特征融合模块将信息融合后进行故障诊断,获得较高的诊断准确率。文献[18]利用多粒度级联森林模型综合压力、温度、流量等多种信号,实现了对液压泵的健康状态评估。

上述基于多传感器信息融合与深度学习的方法虽然能够实现设备的有效诊断,但都是基于训练数据和测试数据服从同一分布的场景。然而,实际工业生产中的谐波减速器运行工况复杂多变,不同工况下数据分布存在差异,且部分工况高质量带标签的数据稀缺或无法获取,难以满足训练深度学习模型所需的数据量,从而导致建立的故障诊断模型准确率和泛化性较差^[19]。迁移学习则可以借助源域已知的知识,帮助目标域进行问题求解^[20]。无监督领域自适应(unsupervised domain adaptation, UDA)作为迁移学习的分支,可以通过挖掘源域与目标域的内部关联知识,弥合领域间的分布差异,借助源域知识帮助目标域网络完成学习,近年来被广泛应用于机械设备故障诊断中。文献[21]针对不同负载滚动轴承的故障诊断问题,提出将深度置信网络与联合分布适配结合的方法,取得较好效果。文献[22]针对轴承跨域故障诊断时,源域和目标域数据存在较大分布差异而诊断效果差的问题,将最小化最大均值差异(maximum mean discrepancy, MMD)作为目标函数进行优化,获得较高的诊断准确率。文献[23]提出一种深度卷积对抗网络方法,通过 Wasserstein 距离定义域适应损失,结合方差约束,实现了不同工况下轴承的故障诊断。文献[24]利用联合最大均值差异改进域适应损失,实现了滚动轴承由仿真数据到真实数据的无监督跨域迁移。

上述利用单一表示结构的网络提取样本特征,再结合数据分布全局对齐的方法在不同工况设备的故障诊断上取得了较好的效果,但是单一表示结构的网络可能只提取图像亮度、色调和对比度等部分信息,从而获得扭曲或错误的图像信息,使诊断准确率不高^[25]。同时,仅仅采用源域和目标域全局对齐的方式,忽视了源域和目标域子域间的关系,未充分利用两域每个类别间的细粒度信息,也限制了迁移效果^[26]。

基于上述原因,本文针对单一传感器信息获取有限、不同工况数据分布差异大,无监督跨域故障诊断准确率低的问题,提出一种信息融合子域适应的谐波减速器故障诊断方法。该方法综合利用多个传感器的运行信息,构建包含谐波减速器更全面运行信息的融合样本,并引入能覆盖融合样本更充分信息的多表示特征提取结构以改进残差网络。同时,结合局部最大均值差异(local maximum mean discrepancy, LMMD)减小源域和目标域的

子域分布差异,最终实现无监督场景中不同工况下谐波减速器的有效诊断。

1 基于小波变换的图像融合

图像融合是指将两幅或多幅图像的信息进行整合,以获取对同一对象的更准确、全面、可靠描述的过程。小波变换具有多分辨率的特点,基于小波变换的图像融合方法能在多个原始图像中选择出较为显著的特征。具体流程如图 1 所示。




图 1 小波变换的图像融合方法流程

Fig. 1 Process of image fusion using wavelet transform

- (1) 对待融合的各图像进行小波分解,得到各图像的高频分量和低频分量;
- (2) 图像的边缘等对比度较为显著的特征对应于绝对值较大的高频系数,而图像的轮廓等特征与低频系数相关。本文采用高频分量取极大值,低频分量取平均值的融合规则对各图像的高频分量与低频分量进行融合;
- (3) 将融合后的高频分量与低频分量通过小波逆变换操作,得到融合图像。

2 改进的残差网络

2.1 残差网络

卷积神经网络(convolution neural network, CNN)是一种被广泛使用的深度神经网络,拥有较强的特征提取能力。但随着网络层数的增加,CNN 可能存在梯度消失、梯度爆炸和网络退化等问题,其结构如图 2 所示^[27]。

残差网络(residual network, ResNet)在 CNN 的基础上发展而来,通过在网络层进行恒等映射操作后,再叠加非线性变换共同作为输出的方式,解决了 CNN 随网络层数的增加造成的梯度消失等问题。残差块作为残差网络的基本单元,其结构如图 3 所示。

残差块的输入为 x ,输出为 $H(x)$,残差即为 $H(x)$ 与 x 的差值,即:

$$f(x) = H(x) - x \quad (1)$$

残差网络的核心是学习函数 $f(x)$,与传统 CNN 不同,仅学习残差块输入与输出差别的方式,降低了学习难度,避免了随着网络层数增加带来的网络性能下降问题。




图 2 卷积神经网络结构

Fig. 2 The structure of convolutional neural network




图 3 残差块结构

Fig. 3 The structure of residual block

2.2 残差网络的改进

ResNet 的输出可简单表示为:

$$y = (g \circ h \circ s)(x) \quad (2)$$

式中: x 表示网络的输入, y 表示网络的输出, $\circ$ 表示复合计算。 $g(\cdot)$ 通过卷积等操作将原始图像转变成低像素图像; $h(\cdot)$ 利用池化等操作提取低像素图像的特征表示; $s(\cdot)$ 作为分类器利用特征进行标签预测。

残差网络的全局池化层利用多表示特征提取结构替换后,可获得样本多表示特征,改进的残差网络结构如图 4 所示。

多表示特征提取结构包括 n 个互不相同的子结构 $h_1(\cdot), \dots, h_n(\cdot)$,从而可以提取输入数据的多表示特征:

$$(h_1 \circ g)(x), \dots, (h_n \circ g)(x) \quad (3)$$

此时,改进残差网络的输出 $f(x)$ 可表示为:

$$y = s([(h_1 \circ f)(x); \dots; (h_n \circ f)(x)]) \quad (4)$$

利用改进后的残差网络进行域适应相较于原始残差网络而言,可以提取样本的多表示特征从而覆盖样本更多信息,因此,理论上将源域和目标域多表示特征的分布




图4 改进的残差网络结构图

Fig. 4 Structure diagram of improved residual network

进行对齐,能获得更好的迁移效果。

3 子域适应

3.1 最大均值差异

在无监督迁移学习中,分为一个有标签样本的源域 $X^s = \{(x_i^s, y_i^s)\}_{i=1}^{n_s}$ 和一个无标签样本的目标域 $X^t = \{x_j^t\}_{j=1}^{n_t}$ 。其中, n_s 表示源域的样本数量, n_t 表示目标域样本数量, y_i^s 是第 i 个源域样本 x_i^s 的标签, x_j^t 代表第 j 个无标签目标域样本。域适应作为迁移学习领域的一个分支,针对目标域无标签的情况,可以通过学习域不变特征,利用源域有标签数据完成对目标域预测函数的学习。传统的域适应方法一般是在全局角度对源域和目标域进行域变换,从而提取全局的域不变特征,提高目标域的预测准确率。

MMD 在迁移学习中被广泛用于衡量两域的分布差异,其定义如公式(5)所示:

$$MMD_H(p, q) = \|E_p[\varphi(X^s)] - E_q[\varphi(X^t)]\|_H^2 \quad (5)$$

式中: H 为再生希尔伯特空间; $\varphi(\cdot)$ 为特征映射; p 为源域样本服从的分布; q 为目标域样本服从的分布; $E_p[\varphi(\cdot)]$ 表示将样本映射到再生希尔伯特空间后的数学期望。

3.2 局部最大均值差异

MMD 主要关注源域和目标域的全局分布匹配,这种方式忽视了域适应过程中类别级的细粒度信息,部分相关性较低的样本经过特征映射后容易被错分类。子域适应方法可以关注源域和目标域相同类别子域的分布匹配,能同时减小源域和目标域样本全局分布差异和相同类别子域间的分布差异。全局域适应和子域适应原理如图5所示。

本文引入 LMMD 代替传统的用于全局分布对齐的




图5 域适应与子域适应

Fig. 5 Domain adaptation and subdomain adaptation

MMD,对源域和目标域中同一类别相关子域进行对齐。LMMD 的计算公式如式(6)所示:

$$d_H = \frac{1}{C} \sum_{c=1}^C \left\| \sum_{x_i^s \in X^s} w_i^{sc} \varphi(x_i^s) - \sum_{x_j^t \in X^t} w_j^{tc} \varphi(x_j^t) \right\|_H^2 \quad (6)$$

式中: x_i^s 代表源域第 i 个样本, x_j^t 代表目标域第 j 个样本, w_i^{sc} 和 w_j^{tc} 分别代表 x_i^s 和 x_j^t 属于类别 c 的权重。样本 x_i 对应的权重 w_i^c 可以通过式(7) 计算得到:

$$w_i^c = \frac{y_{ic}}{\sum_{(x_j, y_j) \in D} y_{jc}} \quad (7)$$

式中: y_{ic} 是第 i 个样本标签向量 y_i 的第 c 个元素。

本文源域采用真实标签计算样本 i 属于类别 c 的权重 w_i^{sc} ,而目标域样本无标签信息则采用分类器输出的概率分布(软标签) 计算样本 j 属于类别 c 的权重 w_j^{tc} 。

利用改进的残差网络提取样本多表示特征,根据式(3),子域适应的计算方式如式(8)所示:

$$\min \sum_i^n d_H((h_i \circ g)(X^s), (h_i \circ g)(X^t)) \quad (8)$$

网络的最终损失为源域交叉熵分类损失与子域适应损失之和,如式(9)所示:

$$\min_f \frac{1}{n_s} \sum_{i=1}^{n_s} J(f(x_i^s), y_i^s) + \lambda \sum_{i=1}^n d_H((h_i \circ g)(X^s), (h_i \circ g)(X^t)) \quad (9)$$

式中: $J(\cdot)$ 代表交叉熵损失函数(分类损失), λ 是域适应衰减项。

4 不同工况下谐波减速器故障诊断及流程

基于信息融合子域适应的不同工况下谐波减速器故障诊断方法框图如图6所示,整体流程框图如图7所示。具体步骤:




图6 故障诊断方法框图

Fig. 6 Diagram of the fault diagnosis method




图7 故障诊断流程框图

Fig. 7 Flow diagram of fault diagnosis

(1) 数据采集:搭建谐波减速器振动信号采集实验平台,安装正常或某种故障类型的谐波减速器,在其不同位置固定振动加速度传感器。利用上位机软件控制驱动电机转速和负载电机载荷以模拟谐波减速器不同的工况。整体调试,完成不同状态谐波减速器不同位置的加速度信号采集工作。

(2) 样本集构建:选取某工况已知标签谐波减速器数据构建源域数据样本集,选取另一工况未知标签谐波减速器数据构建目标域数据样本集,其中目标域数据样本集分为训练样本集和测试样本集。

(3) 数据预处理:将谐波减速器的一维振动信号进行小波变换,转换为二维时频图像以获得样本更丰富的时频信息,为后续多传感器信息融合做准备。

(4) 图像融合:将相同条件下对应不同位置传感器的二维时频图像进行小波分解,得到其高频分量与低频分量,以高频分量取极大值,低频分量取均值的融合规则进行图像融合,得到包含谐波减速器更全面运行信息的融合图像,作为后续网络的输入。

(5) 模型构建:引入多表示特征提取结构改进残差网络,提取源域和无标签目标域融合样本集多表示特征,并得到目标域融合样本的软标签。利用多表示特征计算源域和目标域的局部最大均值差异,将源域分类损失与子域适应损失共同作为网络训练损失,经过一定轮次迭代,通过计算模型损失函数值并使用反向传播方法,计算每个参数的权重,利用梯度下降法更新模型参数,使其向最小化损失函数的方向更新,并最终使目标函数收敛,建立不同工况下谐波减速器的故障诊断模型。

(6) 故障诊断:将目标域用于测试的融合样本输入训练好的网络模型,将模型的预测标签与真实标签进行对比,根据诊断的准确率衡量模型的性能。

5 应用与分析

5.1 实验台搭建及实验环境构建

本文实验数据均来自实验室搭建的谐波减速器振动信号采集实验平台,平台实物图如图8所示。




图8 谐波减速器振动信号采集实验平台

Fig. 8 Harmonic reducer vibration signal acquisition platform

谐波减速器振动信号采集实验平台的测控系统主要是由电机控制箱、驱动电机、转矩转速传感器、待测减速器、负载电机、加速度传感器和数据采集仪等部分组成,示意图如图9所示。加速度传感器可以检测谐波减速器运行时,由于故障而引起的振动变化。同时,在谐波减速器运行过程中,包含故障的结构会发生旋转,为了有效实现谐波减速器一个截面内状态信息的完整获取,本文选用高灵敏度、高可靠性的 HD-YD-215 加速度传感器进行加速度信号的采集,并将传感器 1、传感器 2 和传感器 3 分别在谐波减速器输出端 9 点钟、12 点钟以及 4 点钟方向进行部署,固定在不同位置的加速度传感器以 100 kHz 的采样频率采集不同状态谐波减速器加速度信号,如图 10 所示。

5.2 实验数据集介绍

本文以绿的谐波 LCSG-32-50-C-I 型谐波减速器为例,从谐波减速器的结构和实际失效情况两方面出发,完




图 9 测控系统
Fig. 9 Measurement and control system



图 10 传感器的部署
Fig. 10 Deployment of sensors

成谐波减速器不同故障类型的加工。数据包括柔性轴承内圈轻度、中度、重度故障,柔性轴承外圈轻度、中度、重度故障,滚动体重度故障,刚轮缺齿故障,柔轮缺齿故障和正常状态,共 10 类状态。其中,柔性轴承的轻度、中度、重度故障分别对应激光点蚀 1 次、5 次和 10 次。为便于后续对谐波减速器数据的表述,现对谐波减速器的 10 类状态进行设定,具体设定如表 1 所示。以 OR5 为例,其代表谐波减速器柔性轴承外圈中度故障。

表 1 不同状态类型数据的表示方法

Table 1 Representation methods of different state types data

故障位置	故障程度	表示方法
柔性轴承内圈	轻度	IR1
	中度	IR5
	重度	IR10
柔性轴承外圈	轻度	OR1
	中度	OR5
	重度	OR10
柔性轴承滚动体	重度	B10
刚轮	缺齿故障	CMT
柔轮	缺齿故障	FMT
正常状态	无	N

本文中,谐波减速器的工况共分为 4 种,具体不同工况的描述如表 2 所示。

表 2 谐波减速器不同工况的描述

Table 2 Description of different operating conditions of harmonic reducer

工况	A	B	C	D
转速/rpm	1 000	1 200	1 400	1 600
负载/N·m	10	10	10	10

在数据预处理的过程中,为确保样本包含完整的故障信息,实验以 32 768 个点作为一个样本,然后进行小波变换得到来自单个传感器的时频图,再将多个传感器的时频图进行融合,得到包含更全面运行信息的融合图像。以 A 工况下柔性轴承内圈中度故障为例,图 11(a)、图 11(b)和图 11(c)分别为不同传感器振动信号的时频图,其虚线标记为主要能量分布处,图 11(d)为 3 个传感器信号时频图的融合图像,可见,其包含的信息更加全面。




图 11 A 工况柔性轴承内圈中度故障不同传感器信号时频图与融合图像

Fig. 11 Time-frequency spectrograms and fused images of various sensor signals for moderate faults in the inner race of flexible bearings under condition A

实验共设置 12 个迁移任务,各任务的工况及对应融合样本集设置如表 3 所示。以任务 3 为例,利用 A 工况下 2 000 个已知标签融合图像作为源域训练融合样本集,D 工况下 2 000 个未知标签融合图像作为目标域训练融合样本集,D 工况下另外 1 000 个融合图像作为目标域测试融合样本集。

表 3 各任务工况与融合样本集设置

Table 3 Operating conditions and fusion sample set settings for each task

任务 编号	源域 工况	目标域 工况	源域融合 样本数	目标域融合 样本数(训练/测试)
1	A	B	2 000	3 000(2 000/1 000)
2	A	C	2 000	3 000(2 000/1 000)
3	A	D	2 000	3 000(2 000/1 000)
4	B	A	2 000	3 000(2 000/1 000)
5	B	C	2 000	3 000(2 000/1 000)
6	B	D	2 000	3 000(2 000/1 000)
7	C	A	2 000	3 000(2 000/1 000)
8	C	B	2 000	3 000(2 000/1 000)
9	C	D	2 000	3 000(2 000/1 000)
10	D	A	2 000	3 000(2 000/1 000)
11	D	B	2 000	3 000(2 000/1 000)
12	D	C	2 000	3 000(2 000/1 000)

所提方法激活函数采用 ReLU,模型训练过程中的迭代次数 epochs 设置为 50,学习率 lr 设置为 0.01。

5.3 多传感器与单一传感器对比实验

为了验证基于多传感器信息融合方法在不同工况下谐波减速器故障诊断中的有效性,以任务 1 至任务 4 为例,将多传感器信息融合图像与各单一传感器下的时频图作为输入,利用残差网络结合最大均值差异的全局域适应方法以及本文所提改进残差网络与子域适应结合的方法,分别进行对比实验,具体实验结果如图 12 所示。

由图 12(a)可知,使用原始残差网络提取样本深层特征后进行全局域适应的对比实验中,在任务 1、任务 3 和任务 4 中传感器 1 在单个传感器中的准确率最高,在任务 2 中传感器 2 在单个传感器中的表现最好,但均低于多传感器信息融合后的诊断结果。本实验中,以融合图像作为输入相较于来自单个传感器时频图而言平均准确率分别提升约 1.9%、3%和 6.5%。

由图 12(b)可知,本文所提方法在 4 个迁移任务中,多传感器信息融合后的诊断准确率仍高于单一传感器信息作为输入的准确率。本实验中,以融合图像作为输入相较于来自单个传感器时频图而言平均准确率分别提升约 2.2%、2.1%和 3.6%。其中,在任务 4 中融合图像作为输入相较于表现最差的传感器 3,准确率提升达 4.8%。




图 12 多传感器与单一传感器诊断结果对比

Fig. 12 Comparing the diagnostic results of multi-sensor and single-sensor systems

综上所述,基于多传感器信息融合的方法可以充分利用多个传感器的运行信息用于不同工况下谐波减速器的故障诊断,有效避免单一传感器对于谐波减速器运行信息刻画和不足,更好的实现知识由源域到目标域的迁移。

5.4 残差网络改进前后对比实验

为了探究引入多表示结构的改进残差网络在谐波减速器无监督场景中不同工况下诊断的有效性,分别利用原始的残差网络与改进的残差网络提取多传感器融合图像的深层特征,并利用 t-分布邻域嵌入算法进行特征可视化操作。以任务 1 为例,特征可视化效果图如图 13、图 14 所示。

通过观察图 13 和图 14 可知,在残差网络改进前后,样本均存在错分类的现象,但是二者特征分布存在较大差别。将原始残差网络提取的样本深层特征可视化后,




图 13 原始残差网络特征可视化

Fig. 13 Feature visualization of the original residual network




图 14 改进残差网络特征可视化

Fig. 14 Feature visualization of the improved residual network

不仅在 L1,L4 和 L6 区域存在部分样本错分类,更是在 L2,L3 和 L5 区域还在大量样本特征混叠,边界模糊的现象,而改进后的残差网络提取的样本深层特征仅仅在 L1~L3 区域出现少量样本错分类,类别边界较为明确,可初步判断引入多表示结构改进的残差网络能够更好的提取谐波减速器的深层特征,有助于提升模型的诊断性能。

为了进一步验证改进残差网络,可以更好地提取样本深层特征用于不同工况下谐波减速器的故障诊断,使用 MMD 作为域适应损失,原始的残差网络提取样本的单一表示特征,而改进的残差网络提取样本的多表示特征,以任务 1 为例,将诊断结果绘制混淆矩阵如图 15 和图 16 所示。

通过观察图 15 和图 16 可以发现,当使用原始残差网络提取谐波减速器单一表示特征直接进行特征对齐操作时,模型无法准确区分 OR5、OR10、CMT 和 FMT 四类样本,存在大量的错分类样本,同时 IR5 和 N 类样本也存在少量样本错分类现象。改进的残差网络通过提取谐波减速器多表示特征在多个特征空间中分别进行特征对齐后,虽然 OR5 和 OR10 这两类样本仍存在错分类,但错分




图 15 原始残差网络混淆矩阵

Fig. 15 Confusion matrix of the improved residual network




图 16 改进残差网络混淆矩阵

Fig. 16 Confusion matrix of the improved residual network

类的数量明显减少,且 CMT 和 FMT 两类样本的分类准确性大大提高。综上所述,改进的残差网络可以通过挖掘样本的多表示特征,提取到样本更充分的信息,从而提升谐波减速器在不同工况下的诊断准确率。

5.5 域适应方法改进前后对比实验

为了验证本课题所使用子域适应方法在谐波减速器迁移任务中的有效性,将多传感器融合图像输入单一表示的原始残差网络和引入多表示结构的改进残差网络中,分别以 MMD 和 LMMD 作为域适应损失项,在所有 12 个迁移任务中进行全面实验,为了更清晰表示子域适应方法可以更好地实现不同工况下谐波减速器的故障诊断,将实验结果以雷达图形式表达,如图 17 所示。

由图 17 可知,单一表示和多表示下分别使用 LMMD 代替 MMD 作为域适应损失在各个迁移任务中诊断准确率均有所提高。其中,在单一表示下诊断准确率平均提升 4%,在多表示下诊断准确率平均提升 5.7%。改进的




图 17 域适应方法改进前后对比雷达图

Fig. 17 Comparison of radar charts before and after the improvement of the domain adaptation method

残差网络结合 LMMD 相较于原始残差网络结合 MMD 的方法在 12 个迁移任务中的平均准确率提升 11.4%,尤其在任务 6 中,准确率提升达到了 16.7%。




图 18 所提方法与其他深度迁移学习方法的对比结果

Fig. 18 Comparison results of the proposed method with other deep transfer learning methods

由图 18 的实验结果可以看出,在 12 个不同工况下谐波减速器故障诊断迁移任务中,所提方法诊断准确率均明显高于其他深度迁移学习方法,平均准确率可以达到 98.8%,且相比于 DAN、DAAN、CDAN、DaNN 的深度迁移学习方法,平均准确率分别有 10.2%、7.2%、4.3% 和 8% 的提升,实验表明,所提方法可以有效实现不同工况下谐波减速器的故障诊断。

6 结 论

针对单一传感器不易全面刻画谐波减速器运行特

由上述实验结果分析可知,MMD 虽然可以减小源域与目标域之间的整体分布差异,对于更为细节的类别之间的对齐存在不足,容易造成目标域样本的错分类。LMMD 可以关注到不同类别的细粒度信息,实现源域与目标域不同域各类别子域之间的特征对齐,更准确的提取源域和目标域的域不变特征,提高不同工况下谐波减速器故障诊断的准确率。

5.6 所提方法与其他深度迁移学习方法对比

为了进一步证明本文提出的方法在谐波减速器无监督场景中不同工况下故障诊断问题上的有效性,本文选择深度适配网络 (deep adaptation network, DAN)、动态对抗域适应网络 (dynamic adversarial adaptation network, DAAN)、条件域对抗网络 (conditional domain adversarial network, CDAN)、域适应神经网络 (domain adaptive neural network, DaNN) 4 种深度迁移学习方法进行对比实验。实验中,所有方法均以多传感器信息融合图片作为数据集进行实验,在全部 12 个迁移任务中进行测试,结果如图 18 所示。

征、不同工况数据分布差异大和部分工况无标签造成诊断准确率不高的问题,提出一种信息融合子域适应的故障诊断方法。通过搭建工业机器人谐波减速器故障实验台并进行实验验证,得到如下结论:

(1) 提出基于小波变换图像融合的多传感器信息融合方法,根据高频分量取极大值和低频分量取平均值的融合规则,构建包含更全面运行信息的融合图像。经实测数据验证,利用多个传感器的融合数据相较于单个传感器数据而言,平均准确率至少提升 1.9%,最多提升可达 6.5%,证明了小波变换的图像融合方法在故障诊断中的有效性。

(2) 提出多表示特征提取结构的改进残差网络并结合子域适应将源域和目标域多表示特征的各子域对齐,解决了单一表示特征进行全局分布匹配时效果不佳的问题。在12个迁移任务实验中,改进的残差网络结合LMMD可以更好地提取源域和目标域的域不变特征,相较于原始残差网络结合MMD的方法平均准确率提升11.4%。

(3) 提出一种多传感器信息融合子域适应的不同工况下谐波减速器故障诊断方法。该方法能融合多个传感器信息提高诊断的可靠性,同时实现无监督场景中不同工况下的谐波减速器故障诊断。经实测数据验证,所提方法在12个迁移任务中的平均准确率达到98.8%,且相较于所对比的其他深度迁移方法,准确率至少提升4.3%以上。

实验中已利用实测数据对不同工况下谐波减速器的故障诊断方法进行了充分的实验验证,但未对实际应用条件下、高噪声背景下方法的有效性进行验证,这将是后续研究的重点。

参考文献

- [1] 陈卓凡,周坤,秦菲菲,等. 基于改进量子粒子群算法的机器人逆运动学求解[J]. 中国机械工程,2024,35(2): 293-304.
CHEN ZH F, ZHOU K, QIN F F, et al. Inverse kinematics solution of manipulator based on improved quantum particle swarm optimization [J]. China Mechanical Engineering, 2024,35(2): 293-304.
- [2] LIU L, ZHI Z, YANG Y, et al. Harmonic reducer fault detection with acoustic emission[J]. IEEE Transactions on Instrumentation Measurement, 2023, 72: 3291747.
- [3] ZHI Z, LIU L, LIU D T, et al. Fault detection of the harmonic reducer based on CNN-LSTM with a novel denoising algorithm[J]. IEEE Sensors Journal, 2021, 22(3): 2572-2581.
- [4] XIA B, WANG K, XU A, et al. Intelligent fault diagnosis for bearings of industrial robot joints under varying working conditions based on deep adversarial domain adaptation[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-13.
- [5] WANG J, WAN Z, DONG Z, et al. Research on performance test system of space harmonic reducer in high vacuum and low temperature environment[J]. Machines, 2020, 9(1): 1.
- [6] 康守强,杨加伟,王玉静,等. 基于联邦多表示域适应的不同工况下滚动轴承故障诊断方法[J]. 仪器仪表学报, 2023, 44(6): 165-176.
KANG SH Q, YANG J W, WANG Y J, et al. Fault diagnosis method of rolling bearings under different working conditions based on federated multi-representation domain adaptation [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 165-176.
- [7] 陈仁祥,张勇,杨黎霞,等. 基于整周期数据和卷积神经网络的谐波减速器健康状态评估[J]. 仪器仪表学报,2020, 41(2): 245-252.
CHEN R X, ZHANG Y, YANG L X, et al. Health condition assessment of harmonic reducer based on integer-period data and convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 245-252.
- [8] 陈仁祥,张勇,胡小林,等. 基于电压信号深度特征学习的谐波减速器健康状态识别[J]. 仪器仪表学报,2021, 42(7): 234-241.
CHEN R X, ZHANG Y, HU X L, et al. Health state recognition of harmonic reducer based on depth feature learning of voltage signal [J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 234-241.
- [9] ZHOU X, ZHOU H C, HE Y M, et al. Harmonic reducer in-situ fault diagnosis for industrial robots based on deep learning [J]. Science China Technological Sciences, 2022, 65(9): 2116-2126.
- [10] HE Y, CHEN J, ZHOU X, et al. In-situ fault diagnosis for the harmonic reducer of industrial robots via multi-scale mixed convolutional neural networks[J]. Journal of Manufacturing Systems, 2023, 66: 233-247.
- [11] YANG G, ZHONG Y, YANG L, et al. Fault diagnosis of harmonic drive with imbalanced data using generative adversarial network [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [12] 张洪亮,余其源,秦超群,等. 基于信息融合及双连接注意力残差网络的轴承故障诊断[J]. 振动与冲击, 2023, 42(20): 114-123.
ZHANG H L, YU Q Y, QIN CH Q, et al. Bearing fault diagnosis based on double-connected attention residual network and information fusion[J]. Journal of Vibration and Shock, 2023, 42(20): 114-123.

- [13] WU J, JIANG L, LI J, et al. Discovering new prognostic features for the harmonic reducer in remaining useful life prediction[J]. Shock and Vibration, 2023, 4(5): 2381638.
- [14] SHAO H, LIN J, ZHANG L, et al. A novel approach of multisensory fusion to collaborative fault diagnosis in maintenance[J]. Information Fusion, 2021, 74: 65-76.
- [15] ZHAO X L, JIA M P, DING P, et al. Intelligent fault diagnosis of multichannel motor-rotor system based on multimani-fold deep extreme learning machine[J]. ASME Transactions on Mechatronics, 2020, 25(5): 2177-2187.
- [16] 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 J, WAN A P, WANG J L, 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.
- [17] 张亚洲, 赵小强, 惠永永, 等. 基于多传感器数据融合的 SA-DACNN 齿轮箱故障诊断方法[J/OL]. 控制与决策: 1-9 [2024-02-04]. <https://doi.org/10.13195/j.kzyjc.2023.1367>.
- ZHANG Y ZH, ZHAO X Q, HUI Y Y, et al. SA-DACNN gearbox fault diagnosis method based on multi-sensor data fusion [J/OL]. Journal of Control and Decision: 1-9 [2024-02-04]. <https://doi.org/10.13195/j.kzyjc.2023.1367>.
- [18] 单增海, 李志远, 张旭, 等. 基于多传感器信息融合和多粒度级联森林模型的液压泵健康状态评估[J]. 中国机械工程, 2021, 32(19): 2374-2382.
- SHAN Z H, LI ZH Y, ZHANG X, et al. Health status assessment of hydraulic pumps based on multi-sensor information fusion and multi-grained cascade forest model[J]. China Mechanical Engineering, 2021, 32(19): 2374-2382.
- [19] 侯召国, 王华伟, 熊明兰, 等. 基于迁移学习与加权多通道融合的齿轮箱故障诊断[J]. 振动与冲击, 2023, 42(9): 236-246.
- HOU ZH G, WANG H W, XIONG M L, et al. Gearbox fault diagnosis based on transfer learning and weighted multi-channel fusion [J]. Journal of Vibration and Shock, 2023, 42(9): 236-246.
- [20] 杨大春, 孙宇林, 张春萌, 等. 基于改进残差网络深度子域适应的变工况下滚动轴承故障诊断方法[J/OL]. 轴承: 1-9 [2024-03-10]. <http://kns.cnki.net/kcms/detail/41.1148.TH.20221226.1556.002.html>.
- YANG D C, SUN Y L, ZHANG CH M, et al. Fault diagnosis method of rolling bearing under varying working conditions based on improved residual network deep subdomain adaptation [J/OL]. Bearing: 1-9 [2024-03-10]. <http://kns.cnki.net/kcms/detail/41.1148.TH.20221226.1556.002.html>.
- [21] KANG S Q, CHEN W W, WANG Y J, et al. Method of state identification of rolling bearings based on deep domain adaptation under varying loads[J]. IET Science, Measurement & Technology, 2020, 14(3): 303-313.
- [22] LEI Y G, YANG B, DU Z J, et al. Deep transfer diagnosis method for machinery in big data era. Journal of Mechanical Engineering, 2019, 55(7): 1-8.
- [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. Measurement, 2021, 171: 108767.
- [24] 邵海东, 肖一鸣, 颜深. 仿真数据驱动的改进无监督域适应轴承故障诊断[J]. 机械工程学报, 2023, 59(3): 76-85.
- SHAO H D, XIAO Y M, YAN SH. Simulation data-driven enhanced unsupervised domain adaptation for bearing fault diagnosis [J]. Journal of Mechanical Engineering: 2023, 59(3): 76-85.
- [25] ZHU Y C, ZHUANG F Z, WANG J D, et al. Multi-representation adaptation network for cross-domain image classification[J]. Neural Networks, 2019, 119: 214-221.
- [26] 吴静然, 刘建华, 崔冉. 子域适应无监督轴承故障诊断[J]. 振动与冲击, 2021, 40(15): 34-40.
- WU J R, LIU J H, CUI R. Sub-domain adaptive unsupervised bearing fault diagnosis [J]. Journal of Vibration and Shock, 2021, 40(15): 34-40.
- [27] LÉCUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.

作者简介



康守强,2004 年于哈尔滨理工大学获得学士学位,2007 年于哈尔滨理工大学获得硕士学位,2011 年于白俄罗斯国立大学获得博士学位,现为哈尔滨理工大学教授、博士生导师,主要研究方向为非平稳信号处理,故障诊断、状态评估与预测技术。

E-mail:kangshouqiang@163.com

Kang Shouqiang received his B.Sc. degree in 2004 from Harbin University of Science and Technology, received his M. Sc. degree in 2007 from Harbin University of Science and Technology, received his Ph. D. degree in 2011 from Belarusian State University, now he is Professor and doctoral supervisor in Harbin University of Science and Technology. His main research interests include non-stationary signal processing, fault diagnosis, state evaluation and prediction technology.



章炜东,2019 年于哈尔滨理工大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向为主要研究方向非平稳信号处理,故障诊断、状态评估与预测技术。

E-mail:zhangwd1220@163.com

Zhang Weidong received his B.Sc. degree in 2019 from

Harbin University of Science and Technology, now he is M. Sc. in Harbin University of Science and Technology. His main research interests include non-stationary signal processing, fault diagnosis, state evaluation and prediction technology.



刘连胜(通信作者),2006 年、2008 年和 2017 年于哈尔滨工业大学分别获得学士、硕士和博士学位,现为哈尔滨工业大学副教授,主要研究方向为信息物理系统、基于 FPGA 的高能效计算技术、故障预测与健康

管理等。

E-mail: lianshengliu@hit.edu.cn

Liu Liansheng (Corresponding author) received his B.Sc. , M.Sc. , and Ph. D. degrees all from Harbin Institute of Technology in 2006, 2008, and 2017, respectively. He is currently an associate professor and a Ph. D. advisor at Harbin Institute of Technology. His main research interests include cyber physical system, FPGA-based energy-efficient computing technology, fault prognostics and health management, etc.