

基于多特征空间自适应网络的谐波减速器故障诊断

陈仁祥¹, 张 晓¹, 李嘉琳¹, 杨宝军², 张 旭¹

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室, 重庆 400074; 2. 重庆智能机器人研究院, 重庆 400714)

摘要: 由于多测点位置不同引起的数据分布差异造成谐波减速器故障诊断效果不佳, 提出基于多特征空间自适应网络(multiple feature spaces adaptation network, MFSAN)的谐波减速器故障诊断方法。对谐波减速器振动信号进行连续小波变换, 以构造时频图来描述其运行状态特征。将不同位置传感器所测数据划分为多个源域数据和目标域数据映射到不同特征空间, 得到不同测点位置下的特征表示。利用自适应网络将源域中学习到的知识自动应用到目标域, 以自动对齐特定领域的特征分布, 从而学习多个域不变表示。利用领域特定的决策边界来对齐分类器的输出, 从而有效减少因传感器位置差异引起的数据分布差异。在工业机器人谐波减速器诊断实验中, 所提诊断方法达到了 99.72% 的准确率, 高于其他对比方法, 验证了所提诊断方法的有效性和可行性。

关键词: 故障诊断; 谐波减速器; 连续小波变换; 多特征空间自适应

中图分类号: TH165⁺.3; TH132.46 **文献标志码:** A **文章编号:** 1004-4523(2025)02-0432-09

DOI: 10.16385/j.cnki.issn.1004-4523.2025.02.022

Fault diagnosis of harmonic reducer based on multiple feature spaces adaptive network

CHEN Renxiang¹, ZHANG Xiao¹, LI Jialin¹, YANG Baojun², ZHANG Xu¹

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Robotics Institute, Chongqing 400714, China)

Abstract: Due to the differences in data distribution caused by different locations of multiple measuring points, the fault diagnosis of the harmonic reducer is often ineffective. A fault diagnosis method for the harmonic reducer, based on a multiple feature spaces adaptation network (MFSAN), is proposed. Firstly, the vibration signal of the harmonic reducer is transformed using continuous wavelet transform to construct a time-frequency diagram that characterizes its operational state. Secondly, the data measured by sensors at different positions are divided into multiple source domain and target domain data, which are mapped to different feature spaces to obtain feature representations for each measuring point position. Then, the adaptive network is used to automatically transfer the knowledge learned from the source domain to the target domain features and automatically align the feature distribution of a specific domain to learn multiple domain-invariant representations. Finally, a domain-specific decision boundary is used to align the output of the classifier, effectively solving the data distribution differences caused by sensor location. Experimental results of harmonic reducer diagnosis of an industrial robot show that the identification accuracy of this method is 99.72%, which is higher than that of other comparison methods. The effectiveness and feasibility of this method are thus verified.

Keywords: fault diagnosis; harmonic reducer; continuous wavelet transform; multiple feature spaces adaptation

谐波减速器结构紧凑、传动比大、回差小、传动精度高^[1], 被广泛应用于工业机器人和航空航天等领域^[2]。谐波减速器由刚轮、柔轮和波发生器组成^[3], 是工业机器人中的易损零部件, 为保证谐波减

收稿日期: 2023-01-25; **修订日期:** 2023-05-17

基金项目: 国家自然科学基金资助项目(52475548); 国家重点研发计划资助项目(2023YFB3406200); 重庆市教委科学技术研究项目(KJZD-M202200701); 重庆市自然科学基金创新发展联合基金资助项目(CSTB2023NSCQ-LZX0127); 重庆市研究生联合培养基地项目(JDLHPYJD2024006)

速器运行可靠,维持工业机器人稳定安全运行及避免重大事故,对其进行故障诊断尤为重要。

为实现谐波减速器故障诊断,陈仁祥等^[4]提出了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方法,将谐波减速器振动信号分割成整周期数据样本并分解获得时频图,最后通过卷积神经网络学习其瞬变特征并输出结果。该方法取得了一定成效,但工业机器人复杂多变的使用场景及循环往复运动的特点导致单一传感器不足以反映谐波减速器运动状态全貌。同时,传感器会随着机器人的运动而运动,加剧了单一传感器对工业机器人运行状态反映的不全面性。因此通常利用多个传感器对设备进行状态监测,以获取更为全面的运行信息,但由于设备尺寸和安装条件问题,传感器无法安装在最敏感的位置。这些问题将限制谐波减速器状态数据的采集,并影响设备故障诊断的准确性^[5]。此外,传感器安装位置不同,其测振方向、信号传递路径均会有所差异,这种差异会导致所采集的信号产生分布差异,必然造成分类性能降低,影响学习模型对目标领域的识别效果^[6]。因此,研究如何有效减小由于传感器位置不同而导致的领域差异可减少传感器对设备安装位置的要求,提高故障诊断的准确性,对谐波减速器进行故障诊断具有极其重要的工程意义。

域自适应(domain adaptation, DA)借助域不变子空间特征构建由源域至目标域的特征知识迁移^[7-8]在故障诊断中得到了成功应用,源域是指含有大量标签的知识样本,目标域是指不含或含少量标签的知识样本。夏懿等^[9]提出了将深度自适应网络用于跨域条件下的轴承故障诊断。LONG等^[10]提出了深度适配网络(deep adaptation network, DAN),将深度卷积神经网络应用到了域适配场景。以上研究主要关注工况域适应,且都是基于单个传感器信息进行的故障诊断,未考虑多个传感器的情况。

在多测点时传感器安装位置必然不同,以其中某个测点数据为源域进行训练,获得有效的分类器。然后通过域自适应,将分类器应用于其他位置传感器采集的数据(即目标域)。源域与目标域来自不同位置传感器,它们之间的特征分布差异将影响设备故障诊断的准确性。

多个不同位置传感器所测数据间的分布差异使其在同一个特征空间中难以对齐(对齐是指将源域的数据样本的投影矩阵进行变换,使得变换后的结果尽可能接近目标域的投影矩阵),造成多个领域的

分布差异难以消除,因此,难以将多个位置传感器数据映射到一个公共特征空间来学习域不变特征。因此使用单源域方法减小因多传感器位置不同导致的数据分布差异具有一定的局限性,无法减小多个源域在同一特征空间中的分布差异。为更好地学习多个域不变表示,并用学习到的多个域不变表示来训练多个特定领域的分类器,将不同位置传感器数据映射到多个特征空间,并对齐特定领域的特征分布。这样得到的不同分类器预测的域特定决策边界附近的目标样本可能会得到不同的标签^[11],再利用特定领域的决策边界将分类器的输出与目标样本对齐。

基于此,提出基于多特征空间自适应网络(multiple feature spaces adaptation network, MFSAN)的谐波减速器故障诊断方法。该方法首先利用连续小波变换(continuous wavelet transform, CWT)多分辨率的特点对谐波减速器振动信号进行分解,获得时频图描述其故障状态特征;再将不同测点位置传感器所测数据划分为源域数据和目标域数据,映射到公共子网络获取其公共特征表示,并将每对源域与目标域数据映射到不同特征空间,得到特定领域的特征表示;最后利用该网络两阶段对齐框架分别对齐源域与目标域在特征空间中的分布以及分类器输出,以减小它们之间的分布差异。

1 理论基础

1.1 连续小波变换原理

假设 $\psi(t)$ 为一能量有限函数, $\psi(t) \in L^2(\mathbf{R})$, $L^2(\mathbf{R})$ 为均方可积空间,其傅里叶变换为 $\hat{\psi}(\omega)$,如果满足以下条件:

$$D_\psi = \int_{-\infty}^{\infty} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < \infty \quad (1)$$

式中, D_ψ 为小波系数。 $\psi(t)$ 经过尺度伸缩和平移后得到小波基函数 $\psi_{a,b}(t)$:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (2)$$

式中, a 为尺度因子, b 为平移因子,且 $a, b \in \mathbf{R}, a \neq 0$,为保证能量恒定,引入规范因子 $\frac{1}{\sqrt{|a|}}$,使得 $\|\psi_{a,b}\|_2 = \|\psi\|_2$ 。

对被分析信号来说, $\psi_{a,b}(t)$ 起着观测窗的作用,因此 $\psi(t)$ 还应该满足一般函数的约束条件:

$$\int_{-\infty}^{\infty} |\psi(t)| dt < \infty \quad (3)$$

故 $\hat{\psi}(\omega)$ 是一个连续函数, 因此为满足式(1)的条件, $\hat{\psi}(\omega)$ 在原点处为 0, 即:

$$\hat{\psi}(0) = \int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (4)$$

对于任意时域信号 $f(t) \in L^2(\mathbf{R})$, 其连续小波变换表达式为^[12]:

$$W_f(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \overline{\psi\left(\frac{t-b}{a}\right)} dt \quad (5)$$

式中, $\overline{\psi(t)}$ 表示 $\psi(t)$ 的共轭。

根据连续小波逆变换, 由 $W_f(a, b)$ 重构得到原时域信号 $f(t)$ 。连续小波逆变换表达式为:

$$f(t) = \frac{1}{D_\psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{a^2} W_f(a, b) \psi\left(\frac{t-b}{a}\right) da db \quad (6)$$

由于 Morlet 小波与旋转机械发生故障时产生的冲击信号形状相似, 故选其为母小波^[13]。

1.2 多特征空间自适应网络对齐原理

针对由测点位置不同引起的数据分布差异大的问题, 建立故障诊断的多特征空间自适应网络, 该网络由故障特征提取和对齐分布两部分组成, 网络结构如图 1 所示。其中, 前者利用领域共享残差网络(residual network, ResNet)提取所有源域和目标域数据中的公共特征表示, 再将每对源域和目标域数据通过其对应的非共享域特定子网络映射到特定特征空间, 在特定领域获得特定特征; 后者通过两阶段对齐框架分别对齐每对源域与目标域在特征空间中的分布和不同分类器的输出。

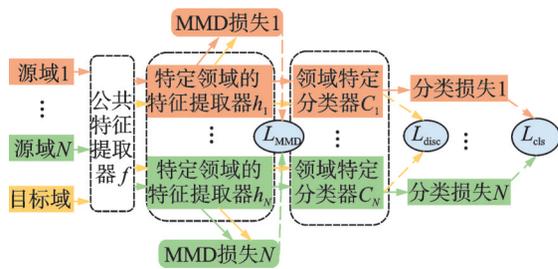


图 1 多特征空间自适应网络结构

Fig. 1 Multiple feature spaces adaptation network structure

1.2.1 特征提取

在多特征空间自适应网络中, 存在 N 个不同源域, 标记源域数据为 $\{(X_{sj}, Y_{sj})\}_{j=1}^N$, 其中 $X_{sj} = \{x_i^{sj}\}_{i=1}^{|X_{sj}|}$ 表示源域 j 的样本, $Y_{sj} = \{y_i^{sj}\}_{i=1}^{|X_{sj}|}$ 表示相应的标签。此外, 在目标分布 $p_t(x, y)$ 中, 对目标域数据

$X_t = \{x_i^t\}_{i=1}^{|X_t|}$ 进行采样, 但目标域数据未被标记。

因多个源域与目标域数据间存在分布差异, 将其映射到同一个特征空间不能很好地学习特定领域的特征表示。所提方法将原始特征空间中源域数据 $\{(X_{sj}, Y_{sj})\}_{j=1}^N$ 和目标域数据 X_t 映射到公共子网络 ResNet 中提取所有域公共特征。之后将这些公共特征 $f(X_{sj})$ 和 $f(X_t)$ 输入到特定领域的特征提取器中, 使每对源域和目标域数据通过对应的非共享域特定子网络映射到特定的特征空间, 从而在特定领域获得特定特征。

1.2.2 两阶段对齐框架

因传感器位置不同, 每对源域和目标域样本的特征分布在不同的域内会产生域间分布差异, 所提方法通过两阶段对齐框架来减小其分布差异。

第一对齐阶段即对齐特定领域的特征提取器中每对源域和目标域的分布。最大平均差异(maximum mean discrepancy, MMD)是衡量数据集分布差异的非参数距离指标^[14], 用于计算域间数据分布差异, MMD 定义为:

$$D_H(h_j(f(X_{sj})), h_j(f(X_t))) \triangleq \left\| \mathbb{E}[\varphi(h_j(f(X_{sj})))] - \mathbb{E}[\varphi(h_j(f(X_t)))] \right\|_H^2 \quad (7)$$

式中, $\mathbb{E}[\cdot]$ 表示期望值; $\|\cdot\|_H$ 表示再生核希尔伯特空间(reproducing kernel hilbert space, RKHS); $\varphi(\cdot)$ 表示将原始样本映射到 RKHS 中后的特征映射。 $f(\cdot)$ 和 $h(\cdot)$ 分别为将所有领域映射到公共特征空间和特定领域的特征提取器; $h_j(f(X_{sj}))$ 和 $h_j(f(X_t))$ 分别为源域数据 X_{sj} 和目标域数据 X_t 在第 j 个特定特征提取网络中的输出。

每个源域和目标域之间差异为:

$$\hat{D}_H(h_j(f(X_{sj})), h_j(f(X_t))) = \left\| \frac{1}{n_s} \sum_{X_i \in D_s} \varphi(X_i) - \frac{1}{n_t} \sum_{X_j \in D_t} \varphi(X_j) \right\|_H^2 \quad (8)$$

式中, n_s 和 n_t 分别表示源域和目标域数据个数; D_s 和 D_t 分别表示源域和目标域数据集; $\hat{D}_H(h_j(f(X_{sj})), h_j(f(X_t)))$ 为 $D_H(h_j(f(X_{sj})), h_j(f(X_t)))$ 的无偏估计量, MMD 损失重新表述为:

$$L_{\text{MMD}} = \frac{1}{N} \sum_{j=1}^N \hat{D}(h_j(f(X_{sj})), h_j(f(X_t))) \quad (9)$$

每个特定的特征提取器可以通过最小化式(9)

来学习每对源域和目标域的域不变表示。所提方法特征提取模块将多个源域数据与目标域数据分别映射于不同特征空间以获得其特定领域的特征表示,利用第一对齐阶段可减小源域与目标域间数据分布差异以学习域不变表示。

每个预测器 C_j 是一个 softmax 分类器,并在第 j 个源域的域特定特征提取器 $h(f(x))$ 之后接收特定的域不变特征。对于每个分类器,将每对源域和目标域样本使用交叉熵损失函数将分类损失添加到每个分类器中,得到分类损失 L_{cls} ,公式如下:

$$L_{cls} = \frac{1}{N} \sum_{j=1}^N \mathbb{E} \left[J \left(C_j \left(h_j \left(f(X_{sj}) \right) \right), Y_{sj} \right) \right] \quad (10)$$

式中, $J(\cdot, \cdot)$ 表示交叉熵损失函数。

分类器在不同源域训练,对目标域样本预测有分歧,将目标域样本输入到不同的特定领域,得到不同分类器预测值,会导致分类性能降低。为解决该问题,提出第二个对齐阶段即最小化所有分类器之间的差异。分类器的输出与目标数据的差异的绝对值被视为分类器间损失:

$$L_{disc} = \frac{2}{N \times (N-1)} \sum_{j=1}^{N-1} \sum_{i=j+1}^N \mathbb{E}_{x \sim X_i} \left[\left| C_i \left(h_i \left(f(X_i) \right) \right) - C_j \left(h_j \left(f(X_i) \right) \right) \right| \right] \quad (11)$$

综上所述,所提方法的损失由三部分组成:分类损失 L_{cls} 、MMD 损失 L_{MMD} 和分类器间损失 L_{disc} 。通过最小化分类损失,网络可以准确地对源域数据进行分类;通过最小化 MMD 损失来学习域不变表示;通过最小化分类器间损失来减小分类器之间的差异。总损失公式为:

$$L = L_{cls} + L_{MMD} + L_{disc} \quad (12)$$

所提方法两阶段对齐框架在不同特征空间中对待每对源域和目标域的特定领域分布以及目标样本特定领域分类器输出,能减小源域与目标域之间的分布差异,有效减小因传感器位置差异引起的分布差异。

2 基于 MFSAN 的谐波减速器故障诊断方法

所提出基于多特征空间自适应网络的谐波减速器故障诊断方法利用两阶段对齐思想对齐多个源域与目标域之间的数据分布,即在多个源域数据和目标域数据映射到公共子网络中得到其公共特征后将

每对源域和目标域数据映射到不同的特征空间,得到不同测点位置下的故障特征表示;然后,构建多个特定域的分类器,使用多个域不变表示来训练多个特定域的分类器以获得每个领域不变表示的识别结果,并利用领域特定的决策边界来对齐分类器的输出。最终有效解决因传感器位置引起数据分布差异的影响。方法流程如图 2 所示。

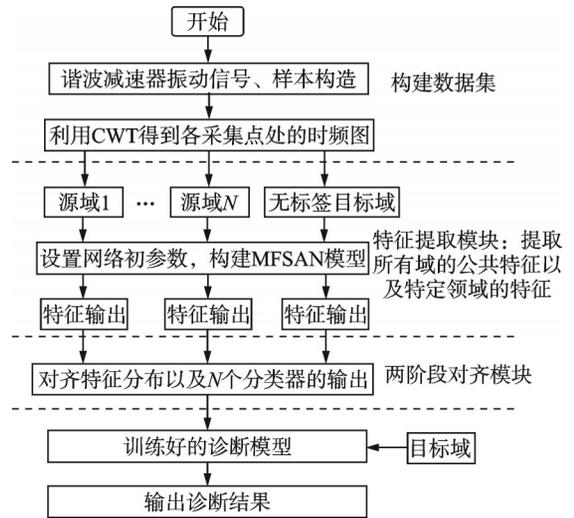


图2 方法流程图

Fig. 2 Flow chart of method

具体步骤如下:

(1) 将不同测点位置的传感器一维原始振动信号分割成整周期数据样本以描述谐波减速器的运行状态信息(整周期分割方法见参考文献[4]);

(2) 利用 CWT 对各传感器下的数据进行分解以获得时频图,并根据传感器位置划分源域(训练集)和目标域(测试集)数据集;

(3) 初始化 MFSAN 网络参数,并将训练集(源域)数据、测试集(目标域)数据以批量的方式输入网络;

(4) 利用公共子网络 ResNet-34 提取所有域公共特征表示,并通过特定领域的特征提取器提取特定域的特征表示;

(5) 利用网络两阶段对齐模块分别对齐每对源域和目标域特定领域的特征分布以及分类器的输出,通过最小化 MMD 损失减小特定领域的特征分布差异,通过最小化分类器间损失减小分类器输出差异,从而有效解决由于传感器位置差异引起的分布差异问题;

(6) 重复步骤(3)~(5),直到训练完毕,得到训练完成的诊断模型,输入测试集数据,得到故障诊断结果,完成谐波减速器的故障诊断。

3 实验验证

3.1 实验数据

实验数据采集自工业机器人末端关节谐波减速器,型号为LHSG-17,传动比为80。谐波减速器共有3种故障状态:间隙过大、卡顿和正常。间隙过大和卡顿状态的谐波减速器为使用单位对工业机器人维修、保养时更换下来的减速器,如图3(a)、(b)所示。传感器布置如图3(c)所示,共有3个不同位置的传感器(测振方向不同),传感器1、2和3采集的数据分别记为A、B和C。

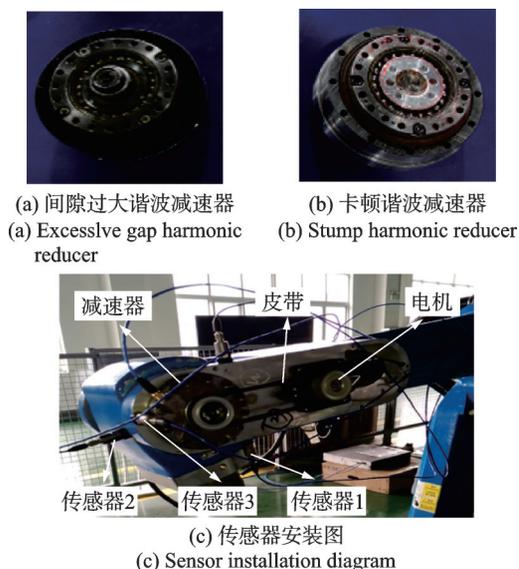


图3 实验装置图

Fig. 3 Experimental device diagram

采样频率为25.6 kHz,在工作节拍为30%满转速及100%满转速的工况下重复采集多组数据,并进行整周期样本分割,每个样本包含88800个采样点,从每类样本中随机选取90个样本,训练集样本每类有70个样本,共210个;测试集样本每类20个样本,共60个。以A、B→C为例,训练数据由有标签训练集A、B和无标签训练集C构成,C为测试集。3种故障类型分别记为类别0~2,具体如表1所示。

表1 谐波减速器数据样本集

Tab. 1 Data sample set of harmonic reducer

故障类型	训练集样本	测试集样本	标签类别
间隙过大	70	20	0
卡顿	70	20	1
正常	70	20	2
合计	210	60	

3.2 数据分析

每种故障状态振动信号时域波形及CWT得到的时频图如图4所示,均通过传感器1获得。根据该图,时域信号无法刻画谐波减速器的瞬变特征。对于时频图,3种不同故障类型下谐波减速器振动信号的能量几乎连续分布于所有频段内,且相对于高频段,低频段内能量明显较高,整个时间段呈现明显的能量波动,间隙过大故障类型的能量明显大于另外两种故障类型。由此,不同故障状态下信号在连续小波时频域表现出的差别明显比在时域所表现的差别更加突出,准确刻画了谐波减速器在一个循环往复周期内的信号变化特点,表明CWT可充分展现不同故障的瞬变特征。

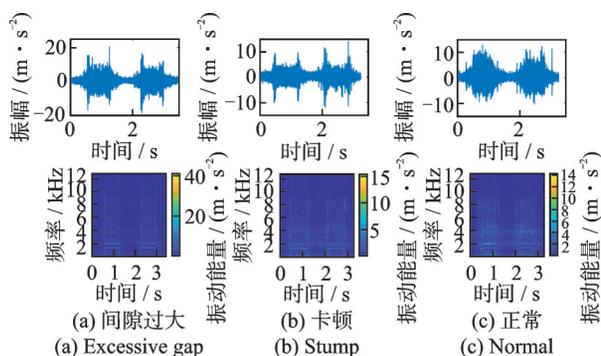


图4 波形图及时频图

Fig. 4 The waveform and time-frequency diagram

图5为同一故障状态(间隙过大)下不同测点位置对应的时频图。由该图可看出,传感器1处所得信号能量几乎连续分布于所有频段内,且相对于高频段,低频段内能量明显较高;传感器2处所得信号能量主要分布在低频范围内;传感器3处所得信号能量分布在低频范围内,且能量显示出更高的值。结果表明,传感器安装位置不同,所得信号能量分布区域不同,且能量有所变化,因此不同测点位置下,谐波减速器故障信号是多样的。

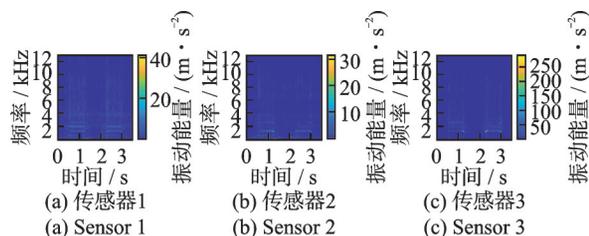


图5 同一故障类型下不同传感器的全周期数据时频图

Fig. 5 Time-frequency diagram of full cycle data of different sensors under the same fault type

3.3 30% 满转速下实验结果及分析

公共子网络采用 ResNet-34 结构,学习率为 0.005,批大小为 32,学习轮数 $k=150$,动量设置为 0.9。将所提方法(CWT+MFSAN)与 CWT+MFSAN_{disc}、CWT+MFSAN_{MMD}、CWT+DAN^[10]、CWT+DDC^[15]、CWT+ResNet^[16]、CWT+DSAN^[17] 几种方法进行对比,以验证所提方法的有效性。其中,源联合下 ResNet 方法进行实验是将多传感器数据同时作为故障诊断模型的输入,对比所提方法,说明对多传感器数据进行域适应的必要性。表 2 为谐波减速器在 30% 满转速工作节拍下的分类准确率,其中多源是指训练集来自多个位置传感器数据,源联合是将混合的多个源域数据作为训练集来测试单个目标域数据,单源是指训练集来自单个传感器数据。

观察表 2,单源适配情况下,ResNet 在同一测点处 A→A 的识别准确率高达 92.25%,但在测点位置不同时平均识别准确率仅为 60.42%,这是由于 ResNet 网络具有良好的特征提取能力,但不具备适配能力,因此不能减小由传感器位置不同导致的数据分布差异。说明为减小数据分布差异,需要对来自不同位置传感器的数据进行域自适应。单源域方法 DDC 与 DAN 平均识别准确率均高于 ResNet,是因为 DDC 与 DAN 均具有适配层,可以减小由传感器位置引起的数据分布差异。与单源域相比,源联

合情况下 DAN、DDC 和 ResNet 的平均识别准确率均高于单源的平均识别准确率,这表明多传感器数据可提高识别精度。

由表 2 可知,源联合情况下,ResNet 识别准确率低于所提方法,因 ResNet 仅将多传感器数据作为输入,且不含适配层,不能减小源域与目标域之间的分布差异,说明了多传感器间进行适配的必要性;因 DDC、DAN 与 DSAN 仅对齐不同传感器特征分布,未考虑分类器输出对齐,很难学习其域不变特征,不能消除多个源域和目标域之间的偏移,故 DDC、DAN 与 DSAN 平均识别准确率均低于所提方法。所提方法分别在不同特征空间学习域不变表示,并在不同特征空间中对齐每对源域和目标域的特定领域分布以及目标样本的特定领域分类器输出,更能减小源域与目标域之间的分布差异。

由表 2 可见,ResNet 在源联合情况下识别准确率仅为 78.89%,比 MFSAN_{MMD} 低 11.67%,说明将多个源域与目标域分别映射到不同的特征空间,对齐每对源域与目标域的特征分布进而学习其特定领域的域不变表示是有必要的。MFSAN_{MMD} 平均识别准确率低于所提方法,说明仅对齐每对源域与目标域在特定特征空间中的特征分布,而不考虑对齐分类器的输出不能很好地减小数据分布差异;同样 MFSAN_{disc} 平均识别准确率也低于所提方法,说明不考虑对齐特征分布仅对齐特定领域分类器的输出

表 2 30% 满转速下的分类准确率

Tab. 2 Classification accuracy at 30% full speed

标准	方法	分类准确率/%							
		A、B→C		A、C→B		B、C→A	平均值	A→A	
多源	MFSAN	100	100	99.17	99.72	—	—	—	
	MFSAN _{MMD}	85.83	96.67	89.17	90.56	—	—	—	
	MFSAN _{disc}	86.67	97.50	84.17	89.45	—	—	—	
源联合	DAN	96.97	85.61	98.48	93.69	—	—	—	
	DDC	94.70	90.91	80.30	88.64	—	—	—	
	DSAN	95.83	98.33	95.83	96.66	—	—	—	
	ResNet	93.33	91.67	51.67	78.89	—	—	—	
单源	DAN	A→C	75.00	A→B	75.76	B→A	81.06	78.92	98.36
		B→C	87.88	C→B	69.70	C→A	84.09	—	—
	DDC	A→C	70.45	A→B	68.18	B→A	62.88	68.69	91.12
		B→C	70.45	C→B	76.52	C→A	63.64	—	—
	DSAN	A→C	88.33	A→B	80.83	B→A	60.83	76.67	97.89
		B→C	94.17	C→B	77.50	C→A	58.33	—	—
	ResNet	A→C	65.83	A→B	64.17	B→A	40.83	60.42	92.25
		B→C	80.83	C→B	69.17	C→A	41.67	—	—

可减小数据的分布差异,但效果不佳。即仅对源域与目标域的特征分布或者分类器的输出进行对齐的方法不能很好地减小数据的分布差异,在对齐特征分布的同时对分类器输出也进行对齐可得到更高的分类准确率,验证了采用两阶段方法对齐数据分布的必要性和有效性。

图 6 给出了 A、B→C 不同方法 (MFSAN、DAN、DDC、ResNet、DSAN) 的概率密度图,同时计算源域和目标域之间的最大平均差异 (MMD) 以分析两个领域间的分布差异。根据图 6(b)、(e) 可看出 MFSAN_{MMD} 对齐源域与目标域的特征分布可拉近域间分布差异。观察该图,DDC、DAN 与 DSAN 具有适配层,可以拉近两域数据分布差异,但效果不佳。由图 6 中 (e)、(f) 可以看出仅对齐特征分布或者分类器输出的方法可以拉近数据分布,但效果不好。MFSAN 的两个不同特征空间的概率密度图如图 6(h) 和 (i) 所示,所提方法源域与目标域几乎重合在一起,效果明显优于其他方法。这是因为所提方法不仅对齐源域与目标域之间的特征分布,并且利用领域特定的决策边界对分类器的输出进行对齐,使得源域与目标域之间的分布更为相近。

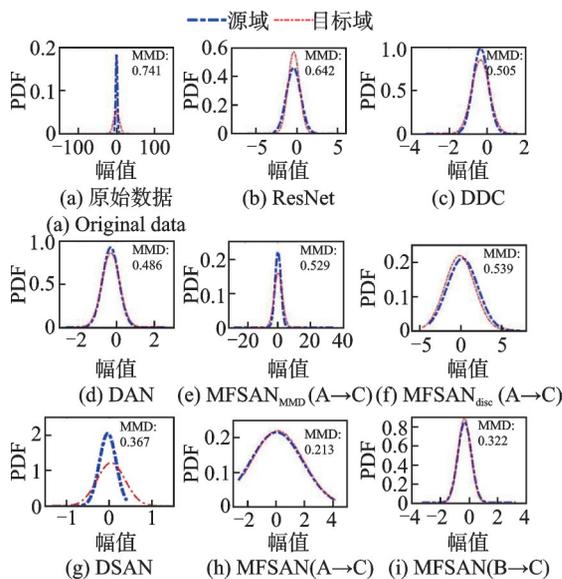


图 6 A、B→C 概率密度图

Fig. 6 A、B→C probability density diagram

进一步分析识别精度较好的几种方法分类准确率随迭代次数的变化,如图 7 所示。随着迭代次数的增加分类准确率不断提高,所提方法始终高于其他方法,且在迭代次数 k 仅为 26 时所提方法准确率已达 100%,说明在迭代次数较少的情况下,所提方法分类准确率更高,收敛速度更快。

考虑到批大小以及学习率对诊断性能的影响,

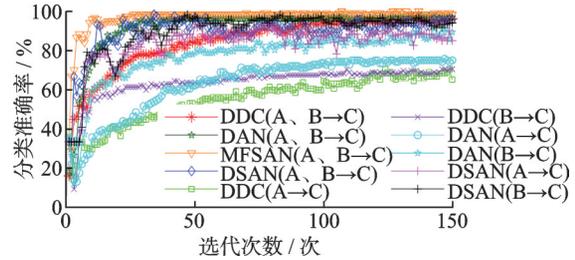


图 7 30% 满转速下不同适配方法分类准确率对比

Fig. 7 Comparison of classification accuracy of different adaptation methods at 30% full speed

以 A、B→C 为例,分别选取不同的批大小以及学习率对不同适配方法进行实验。表 3 和表 4 分别为学习率一定、不同批大小以及批大小一定、不同学习率下各方法的分类准确率。从表 3 和表 4 可看出,批大小以及学习率对各方法的识别准确率均有一定影响。若批大小设置过小,训练时间会过长,而批大小设置过大,占用计算机内存资源会变大,且达到相同准确率所需的迭代次数也会增加,根据表 4,可以看出各方法在批大小为 32 时可达最高的识别准确率;学习率对分类准确率也有一定程度的影响,学习率设置过小时,网络收敛速度下降,若学习率过大会导致无法收敛。因此,各网络均具备一个最佳的批大小以及学习率。

表 3 不同批大小下的分类准确率

Tab. 3 Classification accuracy under different batch sizes

批大小	分类准确率/%				
	MFSAN	DAN	DDC	ResNet	DSAN
8	97.50	96.67	93.38	92.83	93.23
16	98.33	95.83	91.20	90.25	94.31
32	100	96.97	94.70	93.33	95.83
40	96.67	88.33	86.67	80.42	88.64

表 4 不同学习率下的分类准确率

Tab. 4 Classification accuracy under different learning rates

学习率	分类准确率/%				
	MFSAN	DAN	DDC	ResNet	DSAN
0.1	95.68	86.67	80.83	73.56	77.56
0.01	96.36	96.67	94.70	77.50	80.23
0.001	98.33	93.26	89.85	84.17	90.34
0.0001	84.17	81.67	76.67	85.41	95.83
0.00001	83.37	79.58	64.58	93.33	87.15

3.4 100% 满转速下实验结果及分析

为进一步验证所提方法的有效性,在 100% 满

转速工作节拍下重复实验。表5为不同适配方法下的分类准确率。由表5可知,所提方法平均识别准确率可达99.94%,均高于其他方法,这说明所提方法在不同的特征空间分别对齐源域与目标域之间的特征分布以及分类器的输出,可以很好地减小由传感器位置差异引起的数据分布差异,再次证明了该方法的可行性与有效性。

表5 100%满转速下的分类准确率

Tab. 5 Classification accuracy at 100% full speed

方法	分类准确率/%			平均值
	A、B→C	A、C→B	B、C→A	
MFSAN	100	99.83	100	99.94
DAN	94.17	96.67	82.50	91.11
DDC	70.42	95.42	60.42	75.42
DSAN	96.25	92.92	80.83	89.33

图8为在100%满转速工作节拍下不同故障状态下的分类准确率对比结果。根据该图,所提方法的分类准确率随着迭代次数的增加不断提高,且具有较好的识别结果,收敛速度远高于其他方法。进一步说明所提方法是有效的。

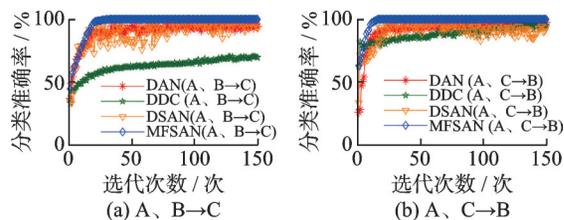


图8 100%满转速下分类准确率对比

Fig. 8 Comparison of classification accuracy at 100% full speed

4 结论

考虑不同安装位置传感器所测数据分布差异影响诊断结果的问题,提出基于多特征空间自适应网络(MFSAN)的谐波减速器故障诊断方法。所提方法通过两阶段对齐,即在不同特征空间中每对源域和目标域的特定领域分布,并利用领域特定的决策边界对分类器的输出进行对齐,最终有效减小因传感器位置差异引起的分布差异。在30%满转速以及100%满转速下谐波减速器故障诊断的实验结果证明了所提方法的可行性与有效性。

参考文献:

- [1] 辛洪兵. 双圆弧谐波齿轮传动基本齿廓设计[J]. 中国机械工程, 2011, 22(6): 656-662.
XIN Hongbing. Design for basic rack of harmonic drive with double-circular-arc tooth profile[J]. China Mechanical Engineering, 2011, 22(6): 656-662.
- [2] LI X Z, SONG C S, YANG Y, et al. Optimal design of wave generator profile for harmonic gear drive using support function[J]. Mechanism and Machine Theory, 2020, 152: 103941.
- [3] 张弦, 姜歌东, 梅雪松, 等. 采用瞬态有限元及加速寿命试验的谐波减速器时变可靠度评估方法[J]. 西安交通大学学报, 2020, 54(4): 1-9.
ZHANG Xian, JIANG Gedong, MEI Xuesong, et al. Time-dependent reliability evaluation method of harmonic drive with transient finite element and accelerated life test[J]. Journal of Xi'an Jiaotong University, 2020, 54(4): 1-9.
- [4] 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 Renxiang, ZHANG Yong, YANG Lixia, 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.
- [5] LIAO M L, LIU C, WANG C, et al. Research on a rolling bearing fault detection method with wavelet convolution deep transfer learning[J]. IEEE Access, 2021, 9: 45175-45188.
- [6] LI X, ZHANG W, DING Q. Cross-domain fault diagnosis of rolling element bearings using deep generative neural networks[J]. IEEE Transactions on Industrial Electronics, 2019, 66(7): 5525-5534.
- [7] ALJUNDI R, EMONET R, MUSELET D, et al. Landmarks-based kernelized subspace alignment for unsupervised domain adaptation[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015: 56-63.
- [8] FERNANDO B, HABRARD A, SEBBAN M, et al. Unsupervised visual domain adaptation using subspace alignment[C]//2013 IEEE International Conference on Computer Vision. Sydney, NSW, Australia: IEEE, 2013: 2960-2967.
- [9] 夏懿, 徐文学. 一种用于跨域轴承故障诊断的深度自适应网络[J]. 振动与冲击, 2022, 41(3): 45-53.

- XIA Yi, XU Wenxue. A deep adaptive network for cross-domain bearing fault diagnosis[J]. Journal of Vibration and Shock, 2022, 41(3): 45-53.
- [10] LONG M S, CAO Y, WANG J M, et al. Learning transferable features with deep adaptation networks[C]//32nd International Conference on Machine Learning: ICML 2015. Lille, France: 2015: 97-105.
- [11] ZHU J, CHEN N, SHEN C Q, et al. Multi-source unsupervised domain adaptation for machinery fault diagnosis under different working conditions[C]//2020 IEEE 18th International Conference on Industrial Informatics (INDIN). Warwick, Kingdom United: IEEE, 2020: 755-762.
- [12] 李宏坤, 刘洪轶, 徐福健, 等. 连续小波最优重构尺度确定方法与故障早期识别[J]. 机械工程学报, 2014, 50(17): 69-76.
- LI Hongkun, LIU Hongyi, XU Fujian, et al. Method for the optimal continuous wavelet reconstruction scale determination and early fault classification[J]. Journal of Mechanical Engineering, 2014, 50(17): 69-76.
- [13] 陈仁祥, 周君, 胡小林, 等. 基于深度Q学习和连续小波变换的旋转机械故障诊断方法[J]. 振动工程学报, 2021, 34(5): 1092-1100.
- CHEN Renxiang, ZHOU Jun, HU Xiaolin, et al. Fault diagnosis method of rotating machinery based on deep Q-learning and continuous wavelet transform[J]. Journal of Vibration Engineering, 2021, 34(5): 1092-1100.
- [14] SCHÖLKOPF B, PLATT J, HOFMANN T. A kernel method for the two-sample-problem[C]//Advances in Neural Information Processing Systems 19: Proceedings of the 2006 Conference. MIT Press, 2007: 513-520.
- [15] TZENG E, HOFFMAN J, ZHANG N, et al. Deep domain confusion: maximizing for domain invariance[EB/OL]. (2014-12-10) [2023-01-25]. <https://arxiv.org/abs/1412.3474v1>.
- [16] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [17] 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.

通信作者: 陈仁祥(1983—), 男, 博士, 教授, 博士生导师。

E-mail: manlou.yue@126.com