

基于动态对抗网络的轴承早期故障诊断*

樊兴华¹, 熊晓燕^{1,2}, 武兵^{1,2}, 李聪明^{1,2}

(1. 太原理工大学机械与运载工程学院 太原, 030024)

(2. 太原理工大学新型传感器与智能控制教育部重点实验室 太原, 030024)

摘要 针对滚动轴承早期故障特征边缘分布与条件分布权重难以调节, 导致分类任务精度低等问题, 提出利用动态对抗自适应网络进行滚动轴承早期故障诊断。首先, 将源域样本和目标域样本视作不同阶段的故障样本, 利用对抗网络减小领域间的分布差异; 其次, 在全局领域判别器和局部子领域判别器的基础上引入动态对抗因子 ω , 动态调节 2 种分布的权重, 减小领域间分布差异; 然后, 耦合特征转换层实现特征多样化, 提升模型泛化性; 最后, 使用转子实验台轴承数据集和凯斯西储大学轴承数据集来验证模型性能。结果表明: 动态对抗自适应网络对 2 个数据集的分类精度均达到 85% 以上, 说明所提出方法能够实现非早期至早期滚动轴承故障的跨域迁移, 为迁移学习理论在轴承以及其他零部件早期故障诊断中的应用提供了一定的理论和技术基础。

关键词 迁移学习; 早期故障诊断; 滚动轴承; 子领域判别器; 动态对抗自适应网络

中图分类号 TH17; TH133.33

引言

滚动轴承是机械设备的关键零部件之一, 由于 40%~70% 的故障是由滚动轴承失效引起的^[1], 因此对其进行早期故障诊断意义重大。

近年来, 迁移学习方法在滚动轴承智能诊断领域受到广泛关注, 成为故障诊断中的研究热点^[2], 其通过领域自适应学习样本间的领域不变特征, 减小领域间分布差异, 缓解目标域缺少样本的问题^[3]。部分学者通过对齐全局领域分布进行故障诊断, 取得了一定的成果。杨彬等^[4]利用多层域适应和伪标签学习的正则化项, 减少故障特征间的分布差异, 实现实验室轴承到机车轴承样本迁移。胡若晖等^[5]提出一种小样本领域自适应的迁移学习模型, 实现多领域特征提取与适配。贾峰等^[6]设计加权领域鉴别器, 增强领域间共有健康样本领域的相似性, 降低领域间额外样本的领域相似性, 克服额外故障样本对模型的影响。也有学者通过减小样本特征的子领域分布(条件分布)差异来提升故障诊断精度。毛文涛等^[7]提出一种多域迁移的深度自编码网络, 提高正常样本与早期故障样本特征间的差异性, 在线检测滚动轴承早期故障。

上述迁移学习方法视边缘分布和条件分布同等重要, 仅利用 2 种分布中的一种进行分布对齐, 但在实际应用中, 不同领域样本 2 种分布的权重难以确定。当领域间分布不相似时, 边缘分布更加重要; 分

布相似时, 条件分布更值得关注, 样本特征多尺度分布对齐, 可有效提升故障样本诊断效果。针对该问题, 吴昊年等^[8]提出改进均衡分布适配(balanced distribution adaptation, 简称 BDA)方法, 利用平衡因子动态调节 2 种分布权重, 构造多个分类器经过一致性判别获得最终识别结果。王肖雨等^[9]利用流形嵌入分布对齐(manifold embedded distribution alignment, 简称 MEDA)将样本特征变换为流形特征, 对流形特征的边缘分布和条件分布给定不同权重进行动态分布对齐。上述方法在迁移特征时存在以下不足: ①样本数量过多时, 以核函数为基础的浅层网络非线性分类能力弱, 难以获取深层特征, 模型泛化弱; ②变工况迁移学习需要人为调整平衡因子, 无法快速有效调整 2 种分布的权重; ③特征分布不同时, 领域自适应难以匹配不同领域, 且针对滚动轴承早期故障诊断的研究较少。

笔者利用动态对抗自适应神经网络(dynamic adversarial adaptation network, 简称 DAAN)^[10]进行滚动轴承早期故障诊断。首先, 网络模型集成特征级转化层可实现特征多样化与均匀化, 提升模型自适应不同领域的性能; 其次, 以标签分类器输出概率对子领域判别器的输入特征进行自适应加权, 增强子领域判别器与故障类别相关性; 其次, 引入动态对抗因子 ω 对样本特征 2 种分布的权重进行调整, 提升模型分类性能与鲁棒性。

* 国家自然科学基金资助项目(51775364); 山西省科技重大专项资助项目(20181102027); 山西省基础研究计划资助项目(202403021221047)

收稿日期: 2022-08-30; 修回日期: 2022-11-26

1 网络架构

1.1 领域自适应

迁移学习方法提取有标签源域样本和无标签目标域样本间的领域不变特征,实现故障诊断。实验室样本包括:源域 $D_s = \{(X_i^s, Y_i^s)\}_{i=1}^{n_s}$ 及源域学习任务 $T_s = \{Y_s, f_s(\cdot)\}$ 、目标域 $D_t = \{(X_j^t, Y_j^t)\}_{j=1}^{n_t}$ 及目标域学习任务 $T_t = \{Y_t, f_t(\cdot)\}$ 。其中: X 为其输入空间; D_s 和 D_t 有相同的标签空间 $Z = \{0, 1, \dots, z-1\}$ 。2个领域的边缘分布不同, $P_s(X_s) \neq P_t(X_t)$, 迁移学习通过获取源域 D_s 和目标域 D_t 之间的距离,减小领域间特征分布的差异,获取有益于目标域的知识。领域自适应需要寻找最佳算法,将源域和目标域特征映射到同一特征空间并对齐,即寻找最佳分类器使领域自适应损失最小。

$$R_s(f) = P_{(X,y) \rightarrow s}[f(X) \neq z] \quad (1)$$

其中: $R_s(f)$ 为分类器损失值; z 为样本 X 的真实标签; $f(X)$ 为样本 X 的预测标签; $P[\cdot]$ 为 $f(X) \neq z$ 的概率。

1.2 动态对抗自适应网络

动态对抗自适应网络目的在于定量评估边缘分布和条件分布的权重。图1为不同领域样本边缘分布和条件分布。如图1(a)所示,对于源域样本,目标域样本不同,边缘分布和条件分布权重不同。由图1(a)迁移到图1(b)时,源域和目标域分布差异较大,此时边缘分布更重要。由图1(a)迁移到图1(c)时,源域和目标域间分布相似,类别间特征差异明显,此时条件分布更重要,但在实际工业活动中,2种分布权重难以确定,如图1(d)所示。

笔者利用DAAN来调节早期故障特征边缘分布与条件分布的权重。DAAN结构如图2所示,由特征提取器、标签分类器、全局领域判别器和局部子领域判别器组成。损失计算公式如下。

1) 标签分类器损失:标签分类器 G_y 输出源域输入样本的伪标签,并与真实标签对比,输出标签分类损失。分类器损失的表达式为

$$L_y = -\frac{1}{n_s} \sum_{X_i \in D_s} \sum_{z=1}^Z P_{X_i \rightarrow z} \log G_y(G_f(X_i)) \quad (2)$$

其中:下标 y 为输入样本类别; $P_{X_i \rightarrow z}$ 为输入样本 X_i 属于类别 z 的概率。

2) 全局领域判别器损失:全局领域判别器使用




图1 不同领域样本边缘分布和条件分布

Fig.1 Marginal distribution and condition distribution of target samples indifferent domain

DANN中的领域判别器,视作源域与目标域样本间的边缘分布。全局领域判别器的损失表达式为

$$L_g = \frac{1}{n_s + n_t} \sum_{X_i \in D_s \cup D_t} L_d(G_d(G_f(X_i)), d_i) \quad (3)$$

其中: G_d 为全局领域判别器; L_d 为交叉熵损失函数; d_i 为输入样本 X_i 的领域标签。

3) 局部子领域判别器损失:局部子领域判别器用于视作源域和目标域各类别样本的条件分布,更适应多模态结构。将领域判别器分割为 y 个子领域判别器 G_d^z ,以加权特征提取器输出特征。局部子领域判别器的损失表达式为

$$L_1 = \frac{1}{n_s + n_t} \sum_{z=1}^Z \sum_{X_i \in D_s \cup D_t} L_d^z(G_d^z(\hat{y}_i^z G_f(X_i)), d_i) \quad (4)$$

其中: G_d^z 为局部子领域判别器; L_d^z 为子领域交叉熵损失函数; $\hat{y}_i^z$ 为输入样本 X_i 预测为类别 z 的概率。




图2 DAAN结构

Fig.2 The structure of DAAN

4) 动态对抗因子 ω :DAAN将全局领域判别器和局部子领域判别器输出特征的A距离作为2种分布的定量计算指标,以此确定动态对抗因子 ω 的值。

$$d_{A,g}(D_s, D_t) = 2(1 - 2(L_g)) \quad (5)$$

$$d_{A,l}(D_s^z, D_t^z) = 2(1 - 2(L_l^z)) \quad (6)$$

$$\hat{\omega} = \frac{d_{A,g}(D_s, D_t)}{d_{A,g}(D_s, D_t) + \frac{1}{Z} \sum_{z=1}^Z d_{A,l}(D_s^z, D_t^z)} \quad (7)$$

其中: d 为A距离。

ω 初始值设为0.5,每个时期通过式(5)~(7)更新 ω 。

第 z 个子领域交叉熵的表达式为

$$L_i^z = \text{crossEntropy}[(\hat{d}_s^z, d_s^z) + (\hat{d}_t^z, d_t^z)] \quad (8)$$

其中: $\hat{d}_s^z$ 为源域样本在第 z 个子领域的概率; $\hat{d}_t^z$ 为目标域样本在第 z 个子领域的概率; $d_s^z = 0, d_t^z = 1$,分别为源域和目标域样本的真实标签。

动态对抗自适应网络的损失函数表达式为

$$L = L_y - \lambda((1 - \omega)L_g + \omega L_l) \quad (9)$$

其中: λ 为平衡参数。

1.3 特征级转化层

特征级转化层在输出特征中添加噪声,使模型泛化能力提升。特征级转化层的表达式为

$$\hat{f}(x) = \gamma f(x) + \beta \quad (10)$$

其中: $\hat{f}(x)$ 为特征转化层输出,增加高斯分布的比例项 γ 和偏差项 β ; $\gamma \sim N(1, \text{softplus}(\theta_\gamma))$; $\beta \sim N(1, \text{softplus}(\theta_\beta))$; softplus 为激活函数; $f(x)$ 为网络模型中间隐含层输出。

1.4 DAAN详细参数

深度神经网络隐含层增加时,网络分类精度升高,但网络隐含层高于4层时,网络分类精度下降且模型泛化性降低,出现过拟合^[11]。表1为DAAN架构参数。其中: K 为卷积核大小及数量(卷积核长 $\times$ 卷积核宽 $\times$ 卷积通道)。

表1 DAAN架构参数

Tab.1 DAAN architecture

名称	K	权值矩阵	步长	输出
输入	—	—	—	400 $\times$ 1
卷积层1	25 $\times$ 1 $\times$ 64	—	2	193 $\times$ 1
卷积层2	15 $\times$ 1 $\times$ 64	—	2	97 $\times$ 1
卷积层2	5 $\times$ 1 $\times$ 50	—	2	49 $\times$ 1
展开层	—	—	—	2 450 $\times$ 1
全连接层1	—	2 450 $\times$ 100	—	100 $\times$ 1
全连接层2	—	100 $\times$ 100	—	100 $\times$ 1
全连接层3	—	100 $\times$ 4	—	4 $\times$ 1

模型第1层卷积核尺寸相对较大,增加网络的感受野,获得全局特征并为后续隐含层提供更多的信息。对于输入信号为一维样本的机械故障诊断而言,大尺寸卷积核有利于抑制高频噪声^[12]。

1.5 DAAN训练流程

与训练阶段对应的故障诊断流程如图3所示,步骤如下。




图3 故障诊断流程

Fig.3 Flowchart of fault diagnosis

1) 准备转子实验台及配套部件,使用软件DEWESoft采集故障样本,针对不同任务将采样本划分为源域样本和目标域样本,并为源域样本添加标签。

2) 搭建训练模型,选择优化器,设定模型超参数。

3) 样本输入特征提取器后输出提取的特征,分类器计算有标签源域样本分类损失函数,若训练结果满足预先设定的要求,则保存结果;否则,调整网络架构和超参数重新训练。

1.6 早期故障诊断定义

以滚动轴承最主要的疲劳点蚀为研究对象,表现为材料的不断剥落,初始形状尺寸较小,点蚀扩展后形成大直径剥落。因此,以不同直径和深度的故障点表示早期点蚀故障与非早期点蚀故障。

2 滚动轴承早期故障诊断实验

在2种数据集中检验网络模型分类效果,并证实该方法对不同任务都有一定的适应性。研究过程中,以电火花方法在滚动轴承相同位置加工不同直

径的单点故障。2 个数据集在训练过程中,DAAN 超参数如表 2 所示。其中:训练过程中一次迭代时训练样本数量为 64;学习率 l 为 0.001。

表 2 DAAN 超参数

Tab.2 DAAN hyper-parameters

超参数	初始值	超参数	初始值
β	0.75	γ	10
p	0	μ	0.01
α	10	λ	0

2.1 实验设备与数据集

使用机械故障仿真台 (mechinery fault simulator lite, 简称 MFSL) 轴承数据集和凯斯西储大学 (Case Western Reserve University, 简称 CWRU) 轴承数据集进行实验。机械故障仿真台如图 4 所示。CWRU 滚动轴承实验平台如图 5 所示。数据集每类样本总采样点数为 120 000。




图 4 机械故障仿真台
Fig.4 Mechinery fault simulator lite




图 5 CWRU 滚动轴承实验平台
Fig.5 CWRU test platform of rolling bearing

转子实验台使用莱克斯诺 ER12K-HFF 3/4 球轴承,采样频率为 12 kHz。CWRU 实验台使用型号为 SKF6205-2RS JEM 的深沟球轴承轴承。数据集均使用电火花烧伤加工单点故障,包含正常、内圈故障、外圈故障和滚动体故障共 4 种状态。以 400 采样点作为一个样本,每类故障包含 300 样本。每个数据集样本总数为 2 400,源域样本、目标域样本和测试样本占比为 2:1:1。其中:MFSL 轴承故障直径包含 1.0、1.5 和 2.0 mm 3 种。MFSL 轴承数据集故障信息如表 3 所示。

CWRU 轴承故障直径包含 0.18、0.36 和 0.54 mm 3 种。CWRU 数据集故障信息如表 4 所示。

表 3 MFSL 轴承数据集故障信息

Tab.3 MFSL datasets of bearing fault

迁移任务	转速/(r·min ⁻¹)	迁移方向
A_1	1 200	1.5 迁移至 1.0
A_2	1 800	1.5 迁移至 1.0
A_3	2 400	1.5 迁移至 1.0
A_4	1 200	2.0 迁移至 1.0
A_5	1 800	2.0 迁移至 1.0
A_6	2 400	2.0 迁移至 1.0

表 4 CWRU 数据集故障信息

Tab.4 CWRU datasets of bearing fault

迁移任务	转速/(r·min ⁻¹)	迁移方向
B_1	1 797	0.36 迁移至 0.18
B_2	1 797	0.54 迁移至 0.18
B_3	1 772	0.36 迁移至 0.18
B_4	1 772	0.54 迁移至 0.18
B_5	1 750	0.36 迁移至 0.18
B_6	1 750	0.54 迁移至 0.18
B_7	1 730	0.36 迁移至 0.18
B_8	1 730	0.54 迁移至 0.18

与迁移成分分析 (transfer component analysis, 简称 TCA)、BDA^[13]、DANN^[14]、深度适配网络 (domain adaptation network, 简称 DAN) 和 MEDA 方法进行对比研究,其中:TCA、BDA 和 MEDA 使用最大均值差异 (maximum mean discrepancy, 简称 MMD) 作为度量准则;DAN 以多核 MMD 为度量准则,以核方法减小领域间分布差异,DANN 利用领域对抗方法减小领域间分布差异。本研究方法分别在 MFSL 和 CWRU 数据集中验证模型性能,网络模型训练中每个独立迁移任务取 10 次实验平均值作为最终精度。

为了直观观察动态影响因子的影响,DAAN 训练阶段参数变化如图 6 所示。动态影响因子从高于 0.5 波动下降至低于 0.5,测试集分类精度波动性升高。可见,领域对抗任务中,模型前期关注子领域分布,后期关注全局领域分布,实现更高精度分类。




图 6 DAAN 训练阶段参数变化
Fig.6 Changed parameter of DAAN in training phase

2.2 特征级转换层对诊断结果影响

以 CWRU 数据集样本为研究对象,模型集成特征级转化层以 Y 表示,模型未集成特征级转化层以 N 表示,网络模型为 DAAN,取 10 次模型测试精度的均值作为对比研究对象,特征级转化层对 CWRU 数据集分类精度影响如表 5 所示。可见,大部分迁移任务中,集成特征级转化层会提升 1%~3% 的模型分类精度,这表明特征级转化层能够增强网络模型的分类性能。特征转化前后特征分布如图 7 所示,转化层实现了特征多样化,转化后特征分布更均匀,模型泛化能力增强。

表 5 特征级转化层对 CWRU 数据集分类精度影响
Tab.5 The influence of classification accuracy by feature-wise transformation layer on CWRU

任务	N/%	Y/%	任务	N/%	Y/%
B_1	88.168	92.908	B_5	92.310	91.856
B_2	88.316	87.708	B_6	87.329	88.775
B_3	90.628	94.376	B_7	85.618	88.229
B_4	95.864	99.772	B_8	86.318	90.694




图 7 特征转化前后特征分布图
Fig.7 Feature distribution before and after feature transformation

2.3 MSFL 数据集故障诊断结果

图 8 为 MFSL 数据集分类结果。TCA、BDA 和

MEDA 等浅层迁移学习方法的分类准确性均小于 DAN、DANN 以及 DAAN 等深层迁移学习方法,这说明在故障诊断领域中,深层网络提取早期故障微弱特征能力更强。DAAN 方法在源域和目标域故障样本占比不平衡时,仍能达到 93.28% 的平均故障精度,该结果表明 DAAN 中的动态影响因子实时调整样本的边缘分布和条件分布,在对齐边缘分布的同时,减小条件分布差异,获得最优权重,在一定程度上提高故障样本的分类精度。




图 8 MFSL 数据集分类结果
Fig.8 The classification accuracy of MFSL datasets

MFSL 数据集混淆矩阵如图 9 所示。DAN 和 DANN 在迁移过程中,内圈和滚动体故障信号微弱,样本特征与正常信号相似,模型学习的特征偏向于对齐边缘分布;外圈故障与其他故障之间差异性大,模型泛化性差。DAAN 模型各类样本分类精度都较高,表明本研究方法提升了故障诊断性能;滚动




图 9 MFSL 数据集混淆矩阵
Fig.9 Confusion matrix of MFSL datasets

体和内圈分类精度低于正常和外圈故障,以振动信号传播路径为例,内圈和滚动体信号传播路径更长,且滚动体、润滑油有一定的缓冲能力,故障信号传播到加速度传感器时相比另外 2 种故障更微弱。以故障机理为例,滚动体与滚道之间存在滑动,导致故障机理更复杂,特征提取困难。因此,内圈和滚动体故障分类精度相对较低。

2.4 CWRU 数据集故障诊断结果

CWRU 数据集分类结果如图 10 所示。浅层迁移学习方法分类效果均低于深层迁移学习方法。其中,DAAN 方法达到 91.79% 的平均分类准确性。该结果表明,本研究方法对不同数据集下变工况迁移学习任务都有一定的泛化性,可用于不同设备零件的早期故障诊断。




图 10 CWRU 数据集分类结果
Fig.10 The classification accuracy of CWRU datasets

CWRU 数据集混淆矩阵如图 11 所示。内圈和滚动体故障样本分类精度较小;内圈有 2.78% 的样

		预测标签			
真实标签	正常	1.000	0	0	0
	滚动体	0	0.983	0	0.017
	内圈	0	0	0.972	0.028
	外圈	0.004	0	0	0.986
		正常	滚动体	内圈	外圈

图 11 CWRU 数据集混淆矩阵
Fig.11 Confusion matrix of CWRU datasets

本被误诊为外圈故障外,其他故障识别精度均超过 98%,说明模型能够有效提取轴承非早期故障和早期故障的共同特征。

2.5 模型可视化

对无监督自编码器算法(auto encoder,简称 AE)、DAN、DANN 及本研究模型输出特征进行 t-SNE 降维处理,将输入的高维特征映射到二维空间,可实现降维可视化。领域特征 t-SNE 可视化结果如图 12 所示。可以看出:AE 无法实现数据聚类;DAN 样本特征降维可视化结果中,源域与目标域同类样本大部分未聚集到一起;DANN 降维可视化结果表明,特征分布更加集中,但部分样本特征未能对齐;DAAN 特征可视化结果中,源域和目标域同类样本特征分布基本对齐,所有样本分类结果基本正确。这证实动态自适应神经网络能从原始振动信号提取更丰富有效的特征,动态自适应因子能更好地平衡边缘分布和条件分布的影响,从而实现高精度的故障诊断。




图 12 领域特征 t-SNE 可视化结果
Fig.12 t-SNE visualization of domain features

3 结 论

1) 使用大量有标签非早期故障样本,模型集成特征转化层可实现特征分布多样化与均匀化,增强

特征分布差异较大的领域。

2) 引入动态影响因子实时调整不同特征分布之间的权重,节省模型训练时间,且源域、目标域同类故障聚类效果更好。

3) 实验结果表明,所提出方法相比其他智能故障识别模型可达到更高的故障识别率,迁移非早期故障数据特征比诊断早期故障数据具有可行性。

参 考 文 献

- [1] BONNETT A H, YUNG C. Increased efficiency versus increased reliability[J]. IEEE Industry Applications Magazine, 2008, 14(1): 29-36.
- [2] 雷亚国, 杨彬, 杜兆钧, 等. 大数据下机械装备故障的深度迁移诊断方法[J]. 机械工程学报, 2019, 55(7): 1-8.
LEI Yaguo, YANG Bin, DU Zhaojun, et al. Deep transfer diagnosis method for machinery in big data era [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8. (in Chinese)
- [3] 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.
JIA Feng, LI Shihao, SHEN Jianjun, et al. Fault diagnosis of rolling bearings using deep transfer learning and adaptive weighting[J]. Journal of Xi'an Jiaotong University, 2022, 56(8): 1-10. (in Chinese)
- [4] YANG B, LEI Y G, JIA F, et al. An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings [J]. Mechanical Systems and Signal Processing, 2019, 122: 692-706.
- [5] 胡若晖, 张敏, 许文鑫. 基于DCGAN和DANN网络的滚动轴承跨域故障诊断[J]. 振动与冲击, 2022, 41(6): 21-29.
HU Ruohui, ZHANG Min, XU Wenxin. Cross-domain fault diagnosis of rolling element bearings using DCGAN and DANN [J]. Journal of Vibration and Shock, 2022, 41(6): 21-29. (in Chinese)
- [6] 贾峰, 李世豪, 沈建军, 等. 面向轴承智能诊断的多领域深度对抗迁移网络[J]. 哈尔滨工业大学学报, 2022, 54(7): 120-127, 135.
JIA Feng, LI Shihao, SHEN Jianjun, et al. Multi-domain deep adversarial transfer network for intelligent diagnosis of bearings [J]. Journal of Harbin Institute of Technology, 2022, 54(7): 120-127, 135. (in Chinese)
- [7] 毛文涛, 田思雨, 窦智, 等. 一种基于深度迁移学习的滚动轴承早期故障在线检测方法[J]. 自动化学报, 2022, 48(1): 302-314.
MAO Wentao, TIAN Siyu, DOU Zhi, et al. A new deep transfer learning-based online detection method of rolling bearing early fault [J]. Acta Automatica Sinica, 2022, 48(1): 302-314. (in Chinese)
- [8] 吴昊年, 陈仁祥, 胡小林, 等. 改进均衡分布适配的滚动轴承寿命阶段识别[J]. 振动工程学报, 2021, 34(1): 194-201.
WU Haonian, CHEN Renxiang, HU Xiaolin, et al. Life stage identification of rolling bearing based on improved BDA method [J]. Journal of Vibration Engineering, 2021, 34(1): 194-201. (in Chinese)
- [9] 王肖雨, 童靳于, 郑近德, 等. 基于流形嵌入分布对齐的滚动轴承迁移故障诊断方法[J]. 振动与冲击, 2021, 40(8): 110-116.
WANG Xiaoyu, TONG Jinyu, ZHENG Jinde, et al. Transfer fault diagnosis for rolling bearings based on manifold embedded distribution alignment [J]. Journal of Vibration and Shock, 2021, 40(8): 110-116. (in Chinese)
- [10] YU C H, WANG J D, CHEN Y Q, et al. Transfer learning with dynamic adversarial adaptation network [C]//2019 IEEE International Conference on Data Mining. Beijing, China: IEEE, 2019: 778-786.
- [11] LAROCHELLE H, BENGIO Y, LOURADOUR, et al. Exploring strategies for training deep neural networks [J]. Journal of Machine Learning Research, 2009, 1(10): 1-40.
- [12] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9-18.
HU Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks [J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18. (in Chinese)
- [13] WANG J D, CHEN Y Q, HAO S J, et al. Balanced distribution adaptation for transfer learning [C]//2017 IEEE International Conference on Data Mining. New Orleans, LA, USA: IEEE, 2017: 1129-1134.
- [14] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. Journal of Machine Learning Research, 2016, 17(1): 2030-2096.



第一作者简介:樊兴华,男,1993年7月生,硕士生。主要研究方向为智能故障诊断及信号检测。

E-mail: fan806002563@163.com

通信作者简介:熊晓燕,女,1970年3月生,博士、教授。主要研究方向为机电系统故障诊断与智能控制、机器人、

E-mail: xxyswl@163.com