

# 采用深度迁移学习与自适应加权的 滚动轴承故障诊断

贾峰<sup>1</sup>, 李世豪<sup>1</sup>, 沈建军<sup>1</sup>, 马军星<sup>1</sup>, 李乃鹏<sup>2</sup>

(1. 长安大学道路施工技术与装备教育部重点实验室, 710064, 西安;

2. 西安交通大学现代设计与转子轴承系统教育部重点实验室, 710049, 西安)

**摘要:** 针对滚动轴承目标域数据中额外故障状态样本影响其故障诊断精度的问题,提出了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。建立特征提取模块,利用深度卷积神经网络将轴承样本映射到高维特征空间;利用迁移学习思想设计加权领域鉴别器,对样本进行自适应加权,并通过在特征空间的对抗训练,增大目标域与源域共有健康状态样本的领域相似性,抑制目标域额外故障状态样本与源域样本的领域相似性增强;依据样本权重,度量目标域与源域样本的相似性,设定阈值将目标域额外故障状态样本标记为未知故障;将源域故障诊断知识迁移到目标域共有健康状态样本的故障识别中。利用齿轮箱轴承数据、凯斯西储大学滚动轴承数据和机车轮对轴承数据对提出的方法进行验证,结果表明:所提方法在3个数据集上均达到89%以上的诊断精度,而对比方法的诊断精度均低于80%。所提方法能够克服额外故障状态样本的影响,有效实现滚动轴承故障诊断。

**关键词:** 滚动轴承;未知故障;卷积神经网络;深度学习;迁移学习;故障诊断

**中图分类号:** TH17 **文献标志码:** A

**DOI:** 10.7652/xjtuxb202208001 **文章编号:** 0253-987X(2022)08-0001-10



OSID 码

## Fault Diagnosis of Rolling Bearings Using Deep Transfer Learning and Adaptive Weighting

JIA Feng<sup>1</sup>, LI Shihao<sup>1</sup>, SHEN Jianjun<sup>1</sup>, MA Junxing<sup>1</sup>, LI Naipeng<sup>2</sup>

(1. Key Laboratory of Road Construction Technology and Equipment of Ministry of Education, Chang'an University,

Xi'an 710064, China; 2. Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System,

Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** This paper proposes a method for fault diagnosis of rolling bearings using deep transfer learning and adaptive weighting considering the fact that the samples in the extra fault category of target domain dataset affects the fault diagnosis accuracy of rolling bearings. Firstly, a feature extraction module is established to map the bearing samples into high-dimensional feature space with deep convolution neural network. Secondly, a weighted domain discriminator is designed based on transfer learning and the samples are adaptively weighted. Through the adversarial training in the feature space, the domain similarity of the samples in the same health status is increased between the target and source domains, and the domain similarity of the samples in extra fault category are suppressed. Then, a threshold is set according to the sample weights and

收稿日期: 2021-12-03。 作者简介: 贾峰(1989—),男,博士,讲师;沈建军(通信作者),男,博士,高级工程师。 基金项目: 国家自然科学基金资助项目(52105085);陕西省自然科学基金基础研究计划资助项目(2020JQ-365);中国博士后科学基金资助项目(2020M683393)。

网络出版时间: 2022-04-29

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20220428.1941.004.html>

domain similarity so as to mark the samples in extra fault category as those with unknown faults. Finally, the fault diagnosis knowledge of source domain is transferred to the fault identification of samples in the same health status in target domain. The proposed method is verified with the gearbox bearing dataset bearing dataset of Case Western Reserve University and locomotive bearing dataset. The results show that the diagnosis accuracy of the proposed method is 89% higher for the three datasets, while that of the method compared is lower than 80%. This indicates that the proposed method can eliminate the influence of extra fault category and realize effective diagnosis of rolling bearing faults.

**Keywords:** rolling bearing; unknown fault; convolution neural network; deep learning; transfer learning; fault diagnosis

基于深度迁移学习的滚动轴承故障诊断方法已经成为研究热点<sup>[1-3]</sup>。该方法通过领域自适应方式,从有标签的滚动轴承训练样本中学习故障诊断知识,迁移知识并识别相似但不同的轴承测试样本中的健康状态信息,其中训练样本称为源域数据集,测试样本称为目标域数据集<sup>[4-5]</sup>。迁移诊断方法克服了训练与测试样本集必须服从相同分布的问题,提高了故障识别的准确率与泛化性<sup>[6-9]</sup>。例如,郭亮等<sup>[10]</sup>提出领域自适应的迁移诊断方法,实现了轴承之间的跨领域诊断;Kumar等<sup>[11]</sup>基于稀疏深度学习模型,提高了迁移模型的故障识别能力;Yang等<sup>[12]</sup>结合领域自适应网络与伪标签学习,实现了滚动轴承的迁移诊断;Qin等<sup>[13]</sup>通过构建共享分类器,提高了轴承迁移诊断的准确率;Jiao等<sup>[14]</sup>构建了残差联合域自适应的轴承迁移诊断方法。

上述迁移诊断方法均假设目标域数据样本与源域数据样本必须具有共同的健康状态<sup>[15-17]</sup>,即闭集诊断,如图1(a)与1(b)中源域数据集A向目标域数据集B的迁移诊断。然而,在工程实际中,目标域数据集不仅包含与源域数据集共有的健康状态,而且往往可能包含在源域数据集中未出现的故障状态,即开集诊断,如图1(a)与1(c)中源域数据集A向目标域数据集C的迁移诊断。在解决闭集诊断问题时,传统迁移诊断方法能够有效实现目标域健康状态的准确识别,如图1(d)所示。但是,当传统迁移方法用于开集诊断时,由于在方法训练时没有额外故障的标记,导致无法识别这些故障,将其错分为其它健康状态,致使诊断精度下降,如图1(e)所示。因此,传统迁移诊断方法无法应对轴承开集诊断的难题。

针对滚动轴承开集诊断问题,可行的解决思路是:在训练中,将额外故障标记为未知故障,进而剔除目标域中额外故障的影响,再利用源域故障信息

实现目标域中共有健康状态的识别,最终实现准确的故障分类,如图1(f)所示。

综上,本文提出了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。该方法首先建立特征提取模块,利用深度卷积神经网络将轴承样本映射到高维特征空间;其次,利用迁移学习思想设计加权领域鉴别器,通过对样本进行自适应加权并结合对抗训练,增大目标域与源域共有健康状态样本的领域相似性,抑制目标域额外故障状态样本与源域的领域相似性,进而设定阈值剔除目标域未知故障样本,实现滚动轴承开集迁移智能诊断。最终,利用3个轴承数据集验证了提出方法的有效性。




图1 滚动轴承的闭集与开集迁移诊断

Fig. 1 Transfer diagnosis of rolling bearings under close set and open set

## 1 基础理论

将深度迁移学习用于轴承故障诊断的主流思路之一是利用领域对抗网络实现源域故障诊断知识向目标域的领域自适应迁移<sup>[18-21]</sup>。在方法中:有标签的源域数据集表示为  $D_s = \{\mathbf{x}_i^s, \mathbf{y}_i^s\}_{i=1}^{n_s}$ , 其中,  $\mathbf{x}_i^s$  表示源域第  $i$  个轴承样本,  $\mathbf{y}_i^s$  表示第  $i$  个样本的故障标签,  $n_s$  表示源域样本数;无标签的目标域数据集表示为  $D_t = \{\mathbf{x}_j^t\}_{j=1}^{n_t}$ , 其中,  $\mathbf{x}_j^t$  表示目标域第  $j$  个轴承样本,  $n_t$  表示目标域样本数。

领域对抗网络(domain adversarial training of neural network, DANN)由 Ganin 等<sup>[22]</sup>提出,通过领域对抗方式增强领域相似性,促使源域与目标域数据在特征空间进行对齐,增强领域数据分布的相似性,实现领域知识的迁移学习。

领域对抗网络主要由 3 部分构成:特征提取器  $G_f$ 、领域鉴别器  $G_d$  和分类器  $G_y$ 。首先,特征提取器主要提取数据深层故障信息;然后,利用对抗学习混淆领域鉴别器,达到提升领域相似性的目的;最后,利用分类器进行识别。损失函数为

$$L(\theta_f, \theta_y, \theta_d) = \frac{1}{n_s} \sum_{i=1}^{n_s} L_y(G_y(G_f(\mathbf{x}_i^s)), \mathbf{y}_i^s) - \frac{\lambda_D}{n_{st}} \sum_{m=1}^{n_{st}} L_d(G_d(G_f(\mathbf{x}_m^{st})), d_m) \quad (1)$$

式中:  $\mathbf{x}_i^s$  表示第  $i$  个样本为源域样本;  $\mathbf{y}_i^s$  表示其故

障标签;  $n_s$  表示源域样本数;  $\mathbf{x}_m^{st}$  表示源域与目标域并集的第  $m$  个样本;  $d_m$  表示第  $m$  个样本的领域标签;  $n_{st}$  表示并集样本数;  $\theta_f, \theta_d$  和  $\theta_y$  分别为  $G_f, G_d$  和  $G_y$  的网络参数;  $L_y$  和  $L_d$  表示分类器和领域鉴别器损失函数;  $\lambda_D$  为权衡参数。领域对抗网络通过优化如下目标完成训练

$$\max_{\theta_d} \min_{\theta_f, \theta_y} L(\theta_f, \theta_y, \theta_d) \quad (2)$$

## 2 故障诊断方法

针对滚动轴承开集迁移诊断问题,引入了共享集与未知集的概念<sup>[16]</sup>,提出了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。该方法由特征提取模块、训练模块与测试模块构成,如图 2 所示。其中:特征提取模块利用深度卷积神经网络提取轴承故障特征;训练模块利用迁移学习思想,通过样本自适应加权实现目标域未知故障识别;在测试模块中,将源域故障诊断知识迁移到目标域共有健康状态样本的故障识别中。

### 2.1 共享集与未知集的定义

在提出方法中,以  $C$  表示共享集,  $\bar{C}$  表示未知集。期望通过训练,将源域与目标域共有健康状态的样本划分为共享集,将目标域中额外故障状态的样本划分为未知集。在共享集中,可利用源域诊断知识识别目标域样本的健康状态;在未知集中,目标




图 2 提出的滚动轴承故障诊断方法

Fig. 2 The proposed fault diagnosis method for rolling bearings

域额外故障样本被标记为未知故障。

## 2.2 特征提取模块

特征提取模块将滚动轴承样本映射到高维特征空间。该模块由卷积神经网络构成,以源域数据  $\{\mathbf{x}_i^s\}_{i=1}^{n_s}$  和目标域数据  $\{\mathbf{x}_j^t\}_{j=1}^{n_t}$  构成的并集  $\{\mathbf{x}_m^{\text{st}}\}_{m=1}^{n_{\text{st}}}$  为输入。将特征提取模块表示为  $G_f$ ,则并集的深层抽象特征为  $\mathbf{x}_{f,m}^{\text{st}}$

$$\mathbf{x}_{f,m}^{\text{st}} = G_f(\mathbf{x}_m^{\text{st}}) \quad (3)$$

式中当第  $m$  个输入样本为源域数据时,并集特征  $\mathbf{x}_{f,m}^{\text{st}}$  可表示为  $\mathbf{x}_{f,m}^s$ 。

## 2.3 训练模块

训练模块主要利用提取的高维故障特征训练具有健康状态识别能力的故障分类器和具有领域属性鉴别能力的领域分类器。然后,设计加权领域鉴别器,用来识别目标域中的未知故障样本。其中,故障分类器表示为  $G_y$ ,领域分类器表示为  $G'_d$ ,加权领域鉴别器表示为  $G_d^w$ 。

### 2.3.1 故障分类器

故障分类器  $G_y$  以源域特征  $\mathbf{x}_{f,m}^s$  为输入,利用监督学习方式,实现轴承故障分类。令故障分类器表示为  $G_y$ ,其结构设计参见文献[22]。源域特征对应的概率预测矩阵为

$$\hat{\mathbf{y}}_m^s = G_y(\mathbf{x}_{f,m}^s) \quad (4)$$

根据式(4),结合源域特征的真实故障标签,故障分类器的损失函数可表示为

$$L_y = \frac{1}{n_s} \sum_{m=1}^{n_s} L(\hat{\mathbf{y}}_m^s, \mathbf{y}_m^s) \quad (5)$$

式中:  $L$  为交叉熵损失函数;  $\mathbf{y}_m^s$  表示第  $m$  个样本的真实故障标签。

### 2.3.2 领域分类器

领域分类器  $G'_d$  旨在度量轴承数据样本的领域信息,判别其属于源域或是目标域,并通过领域对抗方式完成训练。该分类器以并集特征  $\mathbf{x}_{f,m}^{\text{st}}$  为输入,得到样本领域预测概率

$$\hat{d}'_m = G'_d(\mathbf{x}_{f,m}^{\text{st}}) \quad (6)$$

根据上述领域信息,领域分类器的损失函数表示为

$$L'_d = \frac{1}{n_{\text{st}}} \sum_{m=1}^{n_{\text{st}}} L(\hat{d}'_m, d_m) \quad (7)$$

式中  $d_m$  表示第  $m$  个特征的真实领域标签,当其为 0 时表示目标域,为 1 时表示源域。

### 2.3.3 加权领域鉴别器

识别轴承目标域中未知故障样本的可行思路是<sup>[16]</sup>:以传统领域鉴别器的对抗训练为基础,在训

练过程时,对样本进行自适应加权,通过增大目标域共享集与源域的领域相似性,抑制目标域未知集与源域的领域相似性,控制样本权重所度量的领域相似性程度。再通过设置权重阈值,区分源域和目标域中的共享集样本与未知集样本。因此,参考文献[16],设计加权领域鉴别器,其损失函数如下

$$L_d^w = \frac{1}{n_{\text{st}}} \sum_{m=1}^{n_{\text{st}}} L(\hat{d}_m^w, d_m) = \frac{1}{n_s} \sum_{m=1}^{n_s} w_m^s \text{lb}(G_d^w(\mathbf{x}_{f,m}^s)) + \frac{1}{n_t} \sum_{m=1}^{n_t} w_m^t \text{lb}(G_d^w(\mathbf{x}_{f,m}^t)) \quad (8)$$

式中:  $G_d^w$  表示加权领域鉴别器,其网络结构与领域分类器相同,输出为  $\hat{d}_m^w$ ;  $\mathbf{x}_{f,m}^t$  为目标域样本的特征;  $n_s$  表示源域样本总数;  $n_t$  表示目标域样本总数;  $w_m^s$  表示源域样本权重;  $w_m^t$  表示目标域样本权重。

式(8)中领域样本权重是有效识别目标域中未知故障样本的关键,可度量输入样本与源域数据分布的相似程度。源域样本与源域数据分布最相似;目标域共享集与源域具有相同健康状态样本,其分布较为相似;源域与目标域未知集没有相同健康状态样本,分布最不相似。因此,源域样本权重  $w_m^s$ 、目标域共享集样本权重  $w_m^{C_t}$  与未知集样本权重  $w_m^{\bar{C}_t}$  之间应具有逻辑关系

$$w_m^s > w_m^{C_t} > w_m^{\bar{C}_t} \quad (9)$$

式中:上标  $s$  表示源域;  $C_t$  表示目标域共享集;  $\bar{C}_t$  表示目标域未知集。

由此可知,若可以利用训练过程中故障分类器的故障预测信息熵与领域分类器的领域预测概率等信息,计算样本权重,自适应匹配出式(9)中样本权重的逻辑关系,则可控制样本的领域相似性程度,进而识别目标域中的未知集样本。

(1)故障预测信息熵。利用该信息熵可度量故障分类器对故障样本识别的确定性。当故障预测信息熵越小时,表明此样本故障标签越容易确定;反之则较难确定。信息熵计算式为

$$H(\hat{\mathbf{y}}_m) = - \sum \hat{\mathbf{y}}_m \text{lb} \hat{\mathbf{y}}_m \quad (10)$$

式中  $\hat{\mathbf{y}}_m$  表示故障分类器对样本  $\mathbf{x}_m$  的预测结果。

由于故障分类器是由源域数据训练的,源域样本的标签最容易确定,其信息熵最小;目标域共享集样本与源域具有相同健康状态具有相同健康状态,其标签较容易确定,其信息熵较小;目标域未知集与源域没有相同健康状态,其信息熵最大。因此,源域样本、目标域共享集样本和目标域未知集样本的故

障预测信息熵  $H(\hat{\mathbf{y}}_m^s)$ 、 $H(\hat{\mathbf{y}}_m^{C_t})$  和  $H(\hat{\mathbf{y}}_m^{C_t})$  之间的关系为

$$H(\hat{\mathbf{y}}_m^s) < H(\hat{\mathbf{y}}_m^{C_t}) < H(\hat{\mathbf{y}}_m^{C_t}) \tag{11}$$

(2)领域预测概率。该概率为领域分类器的输出值,度量了样本属于源域的概率。源域样本、目标域共享集样本和未知集样本的领域预测概率  $\hat{d}'(\mathbf{x}_m^s)$ 、 $\hat{d}'(\mathbf{x}_m^{C_t})$  和  $\hat{d}'(\mathbf{x}_m^{C_t})$  之间的关系为

$$\hat{d}'(\mathbf{x}_m^s) > \hat{d}'(\mathbf{x}_m^{C_t}) > \hat{d}'(\mathbf{x}_m^{C_t}) \tag{12}$$

(3)权重计算方法。依据故障预测信息熵与领域属性预测概率,可得到样本权重计算公式

$$\omega_m = W(\mathbf{x}_m) = \hat{d}'(\mathbf{x}_m) - \frac{H(\hat{\mathbf{y}}_m)}{T} \tag{13}$$

式中  $T$  表示每次训练时的样本数,使样本故障预测信息熵被归一化至 0~1 之间,确保其与领域预测概率值在同一尺度下。依据式(11)、(12),可知式(13)计算得到的权重具有关系

$$W(\mathbf{x}_m^s) > W(\mathbf{x}_m^{C_t}) > W(\mathbf{x}_m^{C_t}) \tag{14}$$

式(14)得到的权重关系与式(9)设计的权重逻辑关系相匹配,因此可通过设置合理阈值,区分目标域共享集与未知集。

2.4 测试模块

在测试模块中,通过设定合理阈值,识别目标域未知集,进而剔除未知样本的干扰,再利用源域数据训练得到的故障分类器对目标域共享集轴承样本进行识别,公式为

$$\hat{\mathbf{y}}_m = \begin{cases} G_y(\mathbf{x}_{i,m}^t), & \text{若 } \omega_m^t > \omega_0, \text{ 则 } \mathbf{x}_{i,m}^t \in C_t \\ \text{未知故障}, & \text{若 } \omega_m^t < \omega_0, \text{ 则 } \mathbf{x}_{i,m}^t \in \bar{C}_t \end{cases} \tag{15}$$

式中  $\omega_0$  为区分目标域共享集与未知集的阈值。

2.5 故障诊断方法的目标函数

综合轴承故障分类器、领域分类器及加权领域鉴别器的损失函数,得到诊断方法的优化目标

$$\min(L_y + L_d'); \max L_d'' \tag{16}$$

在获取滚动轴承源域与目标域监测数据之后,首先使用归一化方法对数据进行预处理,然后采用 Adam 方法对式(16)进行优化,完成轴承故障诊断方法的训练。


3 实验验证

通过 3 个案例验证提出的滚动轴承故障诊断方法的有效性。

3.1 案例 1:变工况下齿轮箱轴承开集迁移诊断

齿轮箱轴承监测数据采集于如图 3 所示的故障实验台。该实验台由电机、齿轮箱、磁粉制动器等零

部件组成。实验轴承位于齿轮箱输入轴的轴承座内,将加速度传感器吸附在轴承座上方,采集滚动轴承监测数据。



(a) 齿轮箱轴承故障实验台



(b) 轴承内圈故障 (c) 轴承外圈故障 (d) 轴承滚动体故障

图 3 齿轮箱轴承的故障实验台及故障照片

Fig. 3 The photos of test rig and gearbox bearing faults

在故障实验中,实验台通过磁粉制动器为系统提供负载,分别在  $600、1\ 800\ \text{r} \cdot \text{min}^{-1}$  两种不同转速条件下采集两组数据,采样频率为  $5\ \text{kHz}$ 。根据实验转速条件不同,分别定义为数据集 A、B。每个数据集包含 4 种轴承健康状态:正常(N)、内圈故障(IF)、外圈故障(OF)和滚动体故障(RF),每类轴承健康状态样本为 228 个,单个样本的数据长度为 1 044。针对滚动轴承开集诊断实验,依次剔除数据集 A 中内圈故障、外圈故障和滚动体故障样本,并定义为 A1、A2 和 A3。同理,数据集 B 可分别整理为 B1、B2 和 B3。数据集详细信息如表 1 所示。

表 1 不同工况下的齿轮箱轴承数据

Table 1 Gearbox bearing data under different working conditions

| 数据集 | 健康状态       | 转速/( $\text{r} \cdot \text{min}^{-1}$ ) | 总样本数量 |
|-----|------------|-----------------------------------------|-------|
| A   | N/IF/OF/RF | 600                                     | 912   |
| A1  | N/OF/RF    | 600                                     | 684   |
| A2  | N/IF/RF    | 600                                     | 684   |
| A3  | N/IF/OF    | 600                                     | 684   |
| B   | N/IF/OF/RF | 1 800                                   | 912   |
| B1  | N/OF/RF    | 1 800                                   | 684   |
| B2  | N/IF/RF    | 1 800                                   | 684   |
| B3  | N/IF/OF    | 1 800                                   | 684   |

在诊断实验中,分别以 A1、A2 和 A3 为源域数据集、B 为目标域数据集,以 B1、B2 和 B3 为源域数据集、A 为目标域数据集,共可设置 6 组开集诊断任务。为方便表示,使用 A1→B 表示数据集 A1 为源域、数据集 B 为目标域的诊断任务。在训练中,源域数据集的标签已知,目标域数据集的标签未知。使用全部源域数据与 60% 目标域数据作为训练数据,使用剩余 40% 目标域数据作为测试数据。齿轮箱轴承开集迁移诊断实验及数据使用比例如表 2 所示。

表 2 齿轮箱轴承开集迁移诊断实验及数据使用比例

Table 2 Transfer diagnosis experiments and data usage for gearbox bearings under open set

| 诊断任务 | 源域数据集 | 目标域数据集 | 训练数据比例/% |     | 目标域测试数据比例/% |
|------|-------|--------|----------|-----|-------------|
|      |       |        | 源域       | 目标域 |             |
| A1→B | A1    | B      | 100      | 60  | 40          |
| A2→B | A2    | B      | 100      | 60  | 40          |
| A3→B | A3    | B      | 100      | 60  | 40          |
| B1→A | B1    | A      | 100      | 60  | 40          |
| B2→A | B2    | A      | 100      | 60  | 40          |
| B3→A | B3    | A      | 100      | 60  | 40          |

在诊断实验前,对影响提出方法诊断精度的主要因素开展研究工作,即:模型网络深度的确定,式(14)样本权重关系的准确性,阈值  $w_0$  的选择。同时,为保障实验结果具有较好的鲁棒性,在每次诊断任务中,实验重复 10 次,计算平均诊断精度与精度波动方差作为最终结果。

提出方法使用卷积神经网络进行特征提取,其网络深度对开集迁移诊断具有影响,因此首先确定网络深度。卷积神经网络结构主要由卷积层、池化层与激活层重复叠加构成,在实验中将卷积层、池化层与激活层视为 1 层网络深度,则 2~6 层网络深度下的故障识别精度如图 4 所示。可以看出,当网络深度到达 4 后,提出方法诊断精度平稳且波动方差不大,但训练时间仍在增加。因此,在后续实验中将网络深度设置为 4。

式(14)样本权重关系的准确性是提出方法有效区分轴承目标域共享集与未知集的基础。将单次诊断任务的目标域测试样本权重绘制在图 5 中。可以看出,目标域共享集与未知集的样本权重在数值上具有明显差异,因而可以通过设置阈值,对轴承目标域共享集与未知集样本进行识别。




图 4 不同网络深度的对比结果

Fig. 4 Comparison results of different network layers




图 5 目标域测试数据的样本权重

Fig. 5 Sample weights of testing data of target domain

根据图 5 可知,目标域共享集与未知集样本的权重具有明显边界,其阈值可以设置为 0。本文以表 2 中的 6 组实验任务为验证对象,获得不同阈值下轴承开集迁移诊断精度的平均值,如图 6 所示。可以看出,当阈值  $w_0$  为 0 时,提出方法具有最高的诊断精度,且方差较小。因此,将 0 作为区分目标域共享集与未知集样本的阈值。




图 6 不同阈值  $w_0$  下提出方法的诊断精度

Fig. 6 The diagnosis accuracy of the proposed method under different thresholds

将提出方法用于表 2 中的 6 组迁移诊断任务,并与 3 种典型迁移诊断方法进行对比分析。3 种方法分别为:DANN,Tzeng 等<sup>[23]</sup>提出的对抗性领域自适应网络(adversarial discriminative domain ad-

aptation, ADDA), Wang 等<sup>[24]</sup>提出的迁移注意领域自适应网络(transferable attention for domain adaptation, TADA)。在诊断时,3 种典型迁移诊断方法使用的特征提取网络与提出方法相同,以避免特征提取对结果的影响。此外,3 种方法的超参数(学习率、训练批次、误差权衡参数等)均参考原文,以避免因参数设置不合理对诊断结果的影响。上述参数设置在其他诊断案例统一使用。

诊断结果如图 7 所示。可以看出,DANN 对 6 组诊断任务的平均精度为 70.84%,ADDA 的平均精度为 65.12%,TADA 的平均精度为 74.11%,提出的方法平均诊断精度为 91.62%。因此,与传统迁移诊断方法相比,提出方法对滚动轴承开集数据的故障诊断具有显著优势。




图 7 不同方法对变工况下齿轮箱轴承的诊断结果对比  
Fig. 7 Comparison of diagnosis results of gearbox bearings under different conditions by different methods

以实验任务 A1→B 为例,展示不同方法的诊断结果混淆矩阵,如图 8 所示。可以看出:轴承开集数据的故障识别精度,主要在于能否有效剔除目标域中未知故障样本。经典迁移诊断方法 DANN、ADDA 与 TADA 可通过领域自适应方法识别目标域共享集故障样本,但在训练过程中直接对齐源域与目标域数据分布,没有针对未知故障样本采取额外措施,使得目标域未知故障样本被完全错分为其它健康状态,造成方法整体故障识别精度的降低。本文提出的方法首先利用样本权重度量领域相似性,剔除了 71.8%的未知故障样本,再利用故障分类器





图 8 不同诊断方法识别精度的混淆矩阵

Fig. 8 Confusion matrices for the accuracy of different diagnosis methods

实现目标域其他样本的故障识别,使得整体故障识别精度得到明显提升。

3.2 案例 2:凯斯西储大学轴承数据验证

使用凯斯西储大学滚动轴承数据集<sup>[25]</sup>对提出方法进行验证。该数据集包括轴承正常、内圈故障、外圈故障和滚动体故障的样本,每种健康状态样本分别在 0、0.75、1.49、2.24 kW 共 4 种工况下进行采集。因此,该数据集涵盖了不同工况、不同健康状态下滚动轴承的监测数据,故障信息全面,很适合利用该数据集设计开集迁移诊断实验,验证提出方法的有效性。同时,由于数据公开使用,也方便其他学者对比诊断结果。

本文依次将上述 4 种不同工况下的轴承数据集分别定义为数据集 D、E、F、G,每个数据集包含轴承正常状态的 300 个样本、每种故障状态的 200 个样本,每个样本长度为 1 044。针对轴承开集诊断实验,依次剔除数据集 D 中内圈故障、外圈故障和滚动体故障,并定义为 D1、D2 和 D3。实验中,以数据集 D1、D2 和 D3 为源域,以数据集 E、F 和 G 作为目标域,进行 9 组迁移诊断实验,模拟空载工况数据向其他工况数据的迁移诊断。实验设置、参数选择均与案例 1 相同。

不同方法的诊断结果如图 9 所示。可以看出:提出方法的平均诊断精度为 90.57%,而其他 3 种方法诊断精度均未超过 80%。其主要原因在于提出方法设计了加权领域鉴别器,剔除了未知故障样本对迁移诊断的影响,进而提高了诊断精度。

3.3 案例 3:机车轮对轴承开集迁移诊断

针对某型电力机车的轴承状态监测,搭建测试台架,并使用液压系统来驱动和加载,模拟实际工况。该机车使用轴承型号为 552732QT,其监测数据在两种转速波动区间下采集,采样频率为 12.8




图9 凯斯西储大学轴承数据的迁移诊断结果

Fig. 9 Transfer diagnosis results for bearing data of Case Western Reserve University

kHz,低转速区间约为  $490 \sim 530 \text{ r} \cdot \text{min}^{-1}$ ,高转速区间约为  $600 \sim 650 \text{ r} \cdot \text{min}^{-1}$ 。每种转速区间分别采集轴承正常、内圈故障、外圈故障与滚动体故障的加速度信号,故障照片如图10所示。



(a)轴承外圈故障 (b)轴承内圈故障 (c)轴承滚动故障

图10 机车轮对轴承故障照片

Fig. 10 Locomotive bearing failure photos

将两种转速区间下的轴承数据分别记为数据集H与L,每种健康状态有200个样本,每个样本包含1044个数据点。针对轴承开集诊断实验:依次剔除数据集H中内圈故障、外圈故障和滚动体故障的样本,并分别定义为H1、H2和H3;同理,数据集L可分别整理为L1、L2和L3。不同迁移诊断任务的故障识别结果图11所示。可以看出:提出方法在机车轮对轴承开集迁移诊断中平均精度为89.77%,高于其他传统迁移诊断方法,与本文其他两个开集诊断案例的结论相同。




图11 机车轮对轴承的迁移诊断结果

Fig. 11 Transfer diagnosis results for locomotive bearings

## 4 结论

针对滚动轴承目标域额外故障样本影响其故障诊断精度的问题,提出了采用深度迁移学习与自适应加权的轴承故障诊断方法,结论如下。

(1)加权领域鉴别器通过对轴承样本自适应赋予权重,控制样本的领域相似性程度,再利用权重阈值,区分源域和目标域中共享集与未知集样本,降低了未知集样本对轴承迁移诊断的影响。

(2)利用齿轮箱轴承、凯斯西储大学轴承、机车轮对轴承的3个故障诊断案例,验证了提出方法的有效性,相比传统迁移诊断方法,提升了开集数据下滚动轴承的故障识别精度。

(3)通过图8(d)可以看出,提出方法识别未知故障样本的精度为71.8%,究其原因采集轴承样本时,受背景噪声等随机因素影响,部分样本的故障信息被淹没,导致部分未知集样本与轴承目标域共享集样本分布差异性减弱,降低了未知故障样本的识别精度。因此,如何克服随机因素影响、更加有效地计算未知样本权重是后续的重点研究内容。

## 参考文献:

- [1] 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 Xining, YU Di, LIU Shuyu. Fault diagnosis method for small sample bearing based on transfer learning [J]. Journal of Xi'an Jiaotong University, 2021, 55(10): 30-37.
- [2] LEI Yaguo, YANG Bin, JIANG Xinwei, et al. Applications of machine learning to machine fault diagnosis: a review and roadmap [J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [3] 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.
- [4] GUO Liang, LEI Yaguo, XING Saibo, 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.
- [5] WEN Long, GAO Liang, LI Xinyu. 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.
- [6] YANG Bin, LEI Yaguo, JIA Feng, et al. A polynomial kernel induced distance metric to improve deep transfer learning for fault diagnosis of machines [J]. *IEEE Transactions on Industrial Electronics*, 2020, 67(11): 9747-9757.
- [7] 吴春志, 吴守军, 冯辅周, 等. 一种具有强抗噪性的深度学习故障诊断模型 [J]. *西安交通大学学报*, 2021, 55(4): 61-68.
- WU Chunzhi, WU Shoujun, FENG Fuzhou, et al. A deep learning fault diagnosis model with strong anti-noise ability [J]. *Journal of Xi'an Jiaotong University*, 2021, 55(4): 61-68.
- [8] 陈仁祥, 朱玉清, 胡小林, 等. 自适应正则化迁移学习的不同工况下滚动轴承故障诊断 [J]. *仪器仪表学报*, 2021, 42(8): 95-103.
- CHEN Renxiang, ZHU Yuqing, HU Xiaolin, et al. Fault diagnosis of rolling bearing under different working conditions using adaptation regularization based transfer learning [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(8): 95-103.
- [9] CHEN Chao, SHEN Fei, XU Jiawen, et al. Domain adaptation-based transfer learning for gear fault diagnosis under varying working conditions [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-10.
- [10] 郭亮, 董勋, 高宏力, 等. 无标签数据下基于特征知识迁移的机械设备智能故障诊断 [J]. *仪器仪表学报*, 2019, 40(8): 58-64.
- GUO Liang, DONG Xun, GAO Hongli, et al. Feature knowledge transfer based intelligent fault diagnosis method of machines with unlabeled data [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(8): 58-64.
- [11] KUMAR A, VASHISHTHA G, GANDHI C P, et al. Sparse transfer learning for identifying rotor and gear defects in the mechanical machinery [J]. *Measurement*, 2021, 179: 109494.
- [12] YANG Bin, LEI Yaguo, JIA Feng, 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.
- [13] QIN Yi, YAO Qunwang, WANG Yi, et al. Parameter sharing adversarial domain adaptation networks for fault transfer diagnosis of planetary gearboxes [J]. *Mechanical Systems and Signal Processing*, 2021, 160: 107936.
- [14] JIAO Jinyang, ZHAO Ming, LIN Jing, et al. Residual joint adaptation adversarial network for intelligent transfer fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2020, 145: 106962.
- [15] 张庆亮, 朱松豪. 基于对抗学习的开集域自适应分类 [J]. *南京邮电大学学报(自然科学版)*, 2021, 41(3): 93-99.
- ZHANG Qingliang, ZHU Songhao. Open-set domain adaptation classification by adversarial learning [J]. *Journal of Nanjing University of Posts and Telecommunications(Natural Science Edition)*, 2021, 41(3): 93-99.
- [16] YOU Kaichao, LONG Mingsheng, CAO Zhangjie, et al. Universal domain adaptation [C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 2715-2724.
- [17] 陈祝云, 钟琪, 黄如意, 等. 基于增强迁移卷积神经网络的机械智能故障诊断 [J]. *机械工程学报*, 2021, 57(21): 96-105.
- CHEN Zhuyun, ZHONG Qi, HUANG Ruyi, et al. Intelligent fault diagnosis for machinery based on enhanced transfer convolutional neural network [J]. *Journal of Mechanical Engineering*, 2021, 57(21): 96-105.
- [18] LI Weihua, HUANG Ruyi, LI Jipu, et al. A perspective survey on deep transfer learning for fault diagnosis in industrial scenarios: theories, applications and challenges [J]. *Mechanical Systems and Signal Processing, Part A*, 2022, 167: 108487.
- [19] CHEN Zhuyun, GRYLLIAS K, LI Weihua. Intelligent fault diagnosis for rotary machinery using transferable convolutional neural network [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 339-349.
- [20] HE Zhiyi, SHAO Haidong, ZHONG Xiang, et al. Ensemble transfer CNNs driven by multi-channel signals for fault diagnosis of rotating machinery cross working conditions [J]. *Knowledge-Based Systems*, 2020, 207: 106396.
- [21] LI Xiang, ZHANG Wei, DING Qian. Cross-domain fault diagnosis of rolling element bearings using deep generative neural networks [J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(7): 5525-5534.
- [22] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. *The*

- Journal of Machine Learning Research, 2016, 17(1): 2096-2030.
- [23] TZENG E, HOFFMAN J, SAENKO K, et al. Adversarial discriminative domain adaptation [C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 2962-2971.
- [24] WANG Ximei, LI Liang, YE Weirui, et al. Transferable attention for domain adaptation [C]// Proceedings of the AAAI Conference on Artificial Intelligence. Palo Alto, CA, USA: AAAI, 2019: 5345-5352.
- [25] Case Western Reserve University. Bearing data file [DS/OL]. [2022-03-30]. <https://engineering.case.edu/bearingdatacenter/download-data-file>.

(编辑 陶晴 刘杨)