

DOI: 10.19650/j.cnki.cjsi.J1905152

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*

郭亮^{1,2}, 董勋^{1,2}, 高宏力^{1,2}, 李长根^{1,2}

(1.西南交通大学机械工程学院 成都 610031; 2.轨道交通运维技术与装备四川省重点实验室 成都 610031)

摘要:对于智能故障诊断方法,大量有标签数据是实现智能模型训练的必要条件,但该条件在部分工业应用场景下难以满足。难以采集足够有标签数据,尤其是故障状态下的数据,在一定程度上限制了智能故障诊断方法的工业化应用。为解决该问题,提出基于特征知识迁移的机械设备智能故障诊断方法,将实验设备或其他相关设备所采集的足量有标签数据所蕴含的特征知识迁移至工业现场设备所部署的智能模型中,完成不同机械设备之间监测数据的特征知识迁移,从而实现无标签数据下的机械设备智能故障诊断。提出方法首先构建一维深度卷积神经网络,实现从原始振动信号到机械设备故障类别的深度映射。然后在深度卷积神经网络中加入领域适配正则约束项,实现不同机械设备监测数据间特征知识的深度迁移适配。最后,通过全连接神经网络进行机械设备健康状态的识别。为验证提出算法的有效性,通过两种机械设备的轴承在不同性能状态下所采集的监测数据进行迁移故障诊断实验,实验结果表明:提出方法实现了不同设备间监测数据特征知识的迁移适配;相对于传统智能诊断方法,提出的方法在两个数据集之间的迁移故障诊断识别率提高20%以上。

关键词:智能故障诊断;机械设备;迁移学习;特征知识迁移;轴承

中图分类号: TH878 TG115.28 **文献标识码:** A **国家标准学科分类代码:** 460.40

Feature knowledge transfer based intelligent fault diagnosis method of machines with unlabeled data

Guo Liang^{1,2}, Dong Xun^{1,2}, Gao Hongli^{1,2}, Li Changgen^{1,2}

(1.School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China; 2.Technology and Equipment of Rail Transit Operation and Maintenance Key Laboratory of Sichuan Province, Chengdu 610031, China)

Abstract: A large amount of labeled data is a necessary condition for model training of intelligent fault diagnosis methods. However, this condition is difficult to be met in some industrial application scenarios. It is difficult to collect enough labeled data, especially in the fault state. This limits the industrial application of the intelligent fault diagnosis method. To solve this problem, an intelligent fault diagnosis method for mechanical equipment based on feature knowledge transfer is proposed. The characteristic knowledge contained in the sufficient amount of labeled data collected by the experimental equipment or other related equipment is transferred to the intelligent model deployed by an industrial field device. The feature knowledge transfer of monitoring data between different mechanical devices is completed. In this way, the intelligent fault diagnosis of mechanical equipment under unlabeled data can be achieved. First, the proposed method constructs the one-dimensional deep convolutional neural network to realize the depth mapping from the raw vibration signal to the mechanical equipment fault category. Then, the domain adaptation constraint is added to the deep convolutional neural network to realize the deep transfer adaptation of the feature knowledge between different mechanical equipment monitoring data. Finally, the health status of the mechanical equipment is identified by a fully connected neural network. To evaluate the effectiveness of the proposed method, the transfer fault diagnosis experiment is implemented by the monitoring data collected from the bearings of the two mechanical devices under different performance conditions. Experimental results show that the proposed method realizes the transfer and adaptation of the monitoring data feature knowledge between different devices. Compared with the traditional intelligent diagnosis method, the proposed method improves the recognition rate of migration fault diagnosis between two data sets more than 20%.

Keywords: intelligent fault diagnosis; machinery equipment; transfer learning; transfer of characteristic knowledge; bearing

收稿日期:2019-05-15 Received Date:2019-05-15

* 基金项目:国家自然科学基金(51905452)、中央高校基本科研专项(2682017ZDPY09,2682019CX35,2018GF02)资助

0 引言

机械设备智能故障诊断方法从监测信号中提取隐含的故障特征知识,通过智能算法自动识别设备健康状态,是当前故障诊断领域的研究热点^[1]。Cerrada等^[2]提出了随机森林分类器识别齿轮箱健康状态的方法,所提出方法通过齿轮箱实验台所采集数据进行验证。Su等^[3]提出了基于最小二乘支持向量机的多故障诊断方法,采集滚动轴承实验台数据进行提出方法的验证。以上为基于浅层模型的智能故障诊断方法,当前基于深度神经网络的方法在各种公开故障诊断数据集和实验台数据集上取得好的识别效果。Jia等^[4]提出了大数据背景下基于深度神经网络的故障诊断方法,并通过轴承实验室数据进行了方法验证,以浅层网络相比取得了更高的故障识别率。Li等^[5]提出了基于深度统计特征学习的旋转机械故障诊断算法,所提出算法通过齿轮和轴承损伤实验数据进行验证,实验结果表明相对传统智能故障算法,提出算法取得了最好状态识别准确率。Jing等^[6]提出了基于卷积神经网络的特征学习和故障诊断方法,所提方法通过齿轮箱实验台数据进行验证,取得了98%以上的识别准确率。

上述基于浅层和深层模型的智能故障诊断方法在大量有标签数据集上取得了好的故障识别效果。一般而言,采集大量有标签数据从而训练智能识别方法是实现智能故障的必要条件,但是该条件在有些应用场景下却难以满足。在工业应用场景中因为以下两个因素常导致难以采集足够的标签数据:1)部分机械设备安全系数较高,在机械设备出现故障前进行了维护维修策略,导致难以采集到故障状态下的监测信号;2)部分机械设备性能退化历时长,采集足够的全寿命周期监测数据耗时巨大^[7-9]。综上,在工业应用场景下,一般难以采集足够的标签数据,尤其是机械设备在故障状态下的数据。与工业现场有标签数据缺乏形成鲜明对比的是,在实验室条件下可以通过实验设备仿真机械设备的不同运行状态,从而可以采集机械设备在不同状态下的监测数据。但是,实验室所采集的机械设备模拟运行状态监测数据和实际工况条件下所采集的运行状态监测数据之间存在差异,因此通过实验室数据所训练的智能故障诊断模型并不能直接应用在工业现场,这在一定程度限制了智能故障诊断方法的工业化应用。因此,为合理利用实验室大量的有标签数据来消除工业现场难以采集标签数据对智能故障诊断方法的限制,需探索新的解决方案。

迁移学习把一个领域(即源领域)的知识迁移到另外一个领域(即目标领域),使得智能模型可在目标领域能够取得更好的学习效果^[10]。因此迁移学习可解决目标域没有标签数据的问题,该方法已经在图像、语音等领

域得到广泛应用^[11]。目前,在机械故障诊断领域也有一定应用。沈飞等^[12]针对变转速、变负载条件下的电机故障诊断问题,提出了一种基于自相关矩阵奇异值分解的特征提取和迁移学习分类器相结合的诊断方法。陈超等^[13]提出一种基于辅助数据的增强型最小二乘支持向量机(least square support vector machine, LSSVM)迁移学习策略,用于数据量不足时的轴承故障诊断。Wen等^[14]建立了一种新的深度迁移学习故障诊断方法,提出的方法通过不同工况条件下的轴承数据进行验证。Xie等^[15]建立了基于迁移分析的齿轮箱故障诊断方法,通过变负载、变工况下的齿轮实验数据进行算法验证。

以上迁移学习应用在机械设备变工况条件下的智能故障方面取得了好的结果,但是以上研究内容主要针对同一机械设备下不同工况条件之间的迁移,难以适用和解决工业现场设备难以采集足够标签数据的问题。同时,上述研究表明,在实验室条件下可以仿真模拟机械设备的不同运行工况,并且可以采集机械设备在不同健康状态条件下的监测数据。因此,可以将实验室条件下所采集的机械设备监测信号看作源领域,将实际工况条件下所采集的机械监测信号看作目标域。基于此,本文提出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方法。本文方法首先构建一维深度卷积神经网络,从原始振动监测信号中自动的学习信号中所隐藏的机械设备性能状态本征特征知识,然后通过领域适配模块进行源领域和目标领域数据特征知识概率分布的度量和适配,将实验室采集数据中的机械设备性能状态特征知识迁移至缺少标签数据的机械设备,从而实现无标签数据下的机械设备智能故障诊断。

1 问题描述

为更清晰描述要解决问题,介绍迁移学习中的领域概念。令 $\{X, Y\}$ 是有标签数据集, X 是样本, Y 是样本对应标签, $P(X)$ 是样本的边缘概率分布,那么 $D = \{X, P(X)\}$ 是领域, $X = \{x_1, x_2, \dots, x_n\}$ 中 x_n 是样本中的某一项特征值。令 $D_s = \{X^s, P(X^s)\}$ 是源域, $D_t = \{X^t, P(X^t)\}$ 是目标域,本文中源域数据为有标签数据,目标域数据为无标签数据。源域与目标域之间具有相同的标签空间,不同的边缘概率分布。本文方法旨在从有标签源域数据和无标签目标域数据中学习领域不变的特征知识,即源域与目标域数据样本在原始数据空间内存在数据边缘概率分布差异,通过本文算法,将数据从原始数据空间非线性映射到数据特征空间。在数据特征空间内,源域数据特征概率分布和目标域数据特征概率分布尽可能匹配,从而通过源域有标签数据训练的判别模型可有效识别并正确判定目标域数据。

2 深度迁移学习模型

建立深度迁移学习模型,通过源域标签数据和目标域无标签数据训练深度迁移学习模型,从而实现目标域无标签数据的智能故障诊断。如图1所示,本文提出的深度迁移学习模型主要包括两个模块:故障诊断模块和领域适配模块。




图1 深度迁移学习模型

Fig.1 Deep transfer learning model

2.1 故障诊断模块

故障诊断模块由一维深度卷积神经网络构成,一维深度卷积神经网络直接从原始振动信号学习特征知识并识别其表征出来的机械设备性能状态。所构建的深度卷积神经网络主要包括卷积网络单元和全连接网络单元。卷积运算单元从原始振动信号中学习得到信号中所隐含的性能状态特征知识,卷积运算单元主要包括卷积和池化运算形式。

在故障诊断模块中,卷积神经网络的输入是所采集的机械设备的原始振动监测信号 $x_i \in \mathbf{R}^N$,其中振动信号的长度为 N 。

卷积运算是卷积网络单元的基本组成结构,不同的卷积核与输入信号进行卷积运算得到输入信号的不同表征特征。针对振动信号的处理,本文设计卷积运算为一维卷积运算。令输入信号为 $\mathbf{x}$,卷积核的权值矩阵为 $\mathbf{w}_c$,则卷积运算和激活函数运算如下所示:

$$x_j^l = f\left(\sum_{i \in N_j} x_i^{l-1} * \mathbf{w}_{ij}^l + b_j^l\right) \quad (1)$$

式中: x_i^{l-1} 是第 $l-1$ 层的第 i 个特征段; $\mathbf{w}_{ij}^l$ 是第 $l-1$ 层的第 i 个特征段和第 l 层的第 j 个特征段之间的卷积核权值矩阵; b_j^l 是第 l 层的第 j 个特征段所对应的偏置项; $f(\cdot)$ 是激活函数。每个卷积运算层包含多个卷积核,每个卷积核与输入信号运算后学习得到输入信号的特征成分,多个卷积层叠加可学习输入信号不同等级的特征,实现信号的特征知识表征。

池化运算紧邻卷积运算,池化层神经元值与前一层

神经元局部区域相连,通过计算得到局部连接区域的统计特征值。池化运算降低卷积特征的维数从而提高计算效率,与此同时增强卷积特征的旋转不变性,因此一维卷积神经网络可以直接处理具有平移变化性的机械设备振动监测信号。本文使用最大池化运算,使用某一位置及其相邻的总体最大值统计特征来代替网络在该位置的输出。

$$p_j^l = \max\{x_{j \times k:(j+1) \times k}^{l-1}\} \quad (2)$$

式中: p_j^l 是池化运算中第 l 层的第 j 个神经元输出值; $\max\{\cdot\}$ 是池化运算函数,计算特定区域内的最大值; $x_{j \times k:(j+1) \times k}^{l-1}$ 是第 $l-1$ 层的第 j 个局部区域,该区域内神经元段的长度为 k 。

所设计卷积网络单元包含多个卷积和池化运算,输入信号经过卷积网络单元计算后学习得到信号中所隐含的本征特征知识。然后将学习得到的特征知识输入全连接网络进行更高层的特征知识整合并进行状态识别。在全连接网络单元中,网络层之间的神经元全部连接,其计算过程如下:

$$x^l = f\left(\sum x^{l-1} \mathbf{w}_f^l + b_f^l\right) \quad (3)$$

式中: x^{l-1} 是第 $l-1$ 层的输出值; $\mathbf{w}_f^l$ 是第 $l-1$ 层的和第 l 层之间的全连接权值矩阵; b_f^l 是第 l 层所对应的偏置项; $f(\cdot)$ 是激活函数。

2.2 领域适配

故障诊断模块通过所构建的一维卷积神经网络从原始振动信号中提取本征特征知识并对所提取的本征特征知识进行分类,从而判断所采集振动监测信号所表征的机械设备性能状态。故障诊断模块一般通过源域有标签数据进行模型训练,其所提取的振动信号特征知识的概率分布特性未考虑目标域数据的特点。为促进源域数据和目标域数据特征知识的概率分布特性的匹配程度,对源域数据和目标域数据的表征特征进行领域适配。如图1所示,领域特征知识适配将不同域之间的数据特征知识的概率分布差异进行度量并匹配。最大均值差异(maximum mean discrepancy, MMD)用于判断两个分布是否相同,对于以概率分布生成的样本空间为输入的函数,如果两个分布生成的足够多的样本在函数上的对应的均值都相等,那么可认为这两个分布是同一个分布。如果用 Γ 表示一个在样本空间上的连续函数集,那么MMD定义为:

$$D(p, q, \Gamma) = \sup_{f \in \Gamma} (E_{x \sim p}[f(x)] - E_{y \sim q}[f(y)]) \quad (4)$$

式中:数据集合 $\mathbf{x}$ 和 $\mathbf{y}$ 分别满足概率分布 p 和 q 。假设 x_i 和 y_j 是分别从概率分布 p 和 q 通过独立同分布采样得到的数据。可将数据映射到可再生希尔伯特空间内进行最大均值差异近似度量,其度量方式如下所示:

$$D(p, q) = \left\| \frac{1}{n} \sum_{i=1}^n \phi(x_i) - \frac{1}{m} \sum_{j=1}^m \phi(y_j) \right\|_{\mathbf{H}} \quad (5)$$

式中: n 和 m 分别为数据集 $\mathbf{x}$ 和 $\mathbf{y}$ 中的数据数量; $\phi(\cdot)$ 是映射函数; $\|\cdot\|_{\text{H}}$ 是可再生希尔伯特空间。

根据式(5)所定义的最大均值差异近似度量,在所建立的领域适配单元中计算一维卷积神经网络在源域数据和目标域数据输入下模型三层网络输出特征知识的概率分布差异。其计算过程如下所示:

$$D = \sum_{l=1}^{l_2} \left\| \frac{1}{n} \sum_{i=1}^n \varphi(x_i^l) - \frac{1}{m} \sum_{j=1}^m \varphi(y_j^l) \right\|_{\text{H}} \quad (6)$$

式中: n 和 m 分别为源域数据和目标域数据的数据量; l_1 和 l_2 是卷积神经网络领域适配的网络起始层和终止层; x_i^l 是源域数据在第 l 层的输出特征值; y_j^l 是目标域数据在第 l 层的输出特征值。

2.3 模型训练

模型训练过程中,提出模型需要满足两个优化目标:1)最小化故障诊断模块在源域数据上的故障识别准确率;2)最小化源域数据与目标域数据深层次特征知识的概率分布差异。因此,建立如下优化目标函数:

$$\min_{\theta_f, \theta_c} L_c(\theta_f, \theta_c) + \lambda \sum_{l=1}^{l_2} D_l(\theta_f) \quad (7)$$

式中: $L_c(\theta_f, \theta_c)$ 是状态识别模块在源域数据上的故障识别误差; $D_l(\theta_f)$ 是源域数据与目标域数据第 l 层特征知识的概率分布差异; l_1 和 l_2 是卷积神经网络领域适配的网络起始层和终止层。 $\lambda > 0$ 是惩罚项系数,该惩罚项系数控制了模型在源域数据上的故障诊断识别率和模型在不同域数据之间领域适配的权重。

故障诊断模块的识别误差度量了模型在源域数据上的状态识别准确率,其计算如下所示:

$$L_c(\theta_f, \theta_c) = - \sum_k y_k \ln a_k \quad (8)$$

式中: y_k 为输出真值; a_k 为真实输出值。

特征知识的概率分布差值度量了构建模型对于源域数据和目标域数据的深层次特征知识的概率分布差异,其计算如下:

$$D_l(\theta_f) = \left[\frac{1}{m^2} \sum_{i,j=1}^m k(x_i, x_j) - \frac{2}{mn} \sum_{i,j=1}^{m,n} k(x_i, y_j) + \frac{1}{n^2} k(y_i, y_j) \right]^{\frac{1}{2}} \quad (9)$$

式中: m 和 n 是源域数据和目标域数据数量; $k(\cdot, \cdot)$ 是核函数。

模型训练过程中首先使用源域标签数据集对故障诊断模块进行预训练,然后使用源域数据和目标域数据通过随机梯度下降法进行故障诊断模块参数的优化更新,式(7)相对于模型参数 θ 的梯度计算如下所示:

$$\nabla_{\theta} = \frac{\partial L_c(\theta)}{\partial \theta} + \lambda \frac{\partial D(\theta)}{\partial \theta} \quad (10)$$

基于式(10)梯度计算可进行网络模型多层参数的

优化更新。

3 实验验证

为验证本文方法的迁移诊断效果,采集两个轴承实验台在不同性能状态下的监测数据,进行迁移故障诊断实验。为验证本文方法在迁移故障诊断方面的有效性,进行提出方法与其他方法的迁移故障诊断对比实验。

3.1 实验数据

本文实验数据来自于两个不同的故障诊断实验台。一组监测数据来自于凯斯西储大学的轴承实验台,另一组监测数据来自滚子轴承故障模拟实验台。

凯斯西储轴承数据 A: 凯斯西储轴承数据是一个电机轴承在不同性能状态下的振动信号数据集,实验平台如图 2 所示。数据集中电机轴承的状态包括正常、滚珠故障、内圈故障和外圈故障状态。




图 2 凯斯西储轴承实验台

Fig.2 CWRU bearing testbed

滚子轴承实验台数据 B: 滚子轴承实验台数据是在自制滚子轴承性能状态模拟实验台采集轴承监测数据构成的数据集。该数据也包含了轴承在正常状态、滚子故障、内圈故障状态和外圈故障状态下的监测数据。

实验所采集的两个不同轴承实验台的数据均为振动监测数据。实验数据 A 的采样频率为 24 kHz, 实验数据 B 的采样频率为 12.8 kHz。两个数据集中均包含轴承在 4 种不同性能状态下的数据样本, 每类数据样本的数量为 1 000, 单个样本的数据长度为 1 200。

3.2 迁移故障诊断实验

为验证本文算法,进行如表 1 所示的两种迁移故障诊断实验,也就是实验 A→B 和实验 B→A。在每种迁移故障诊断实验中,箭头左侧数据集代表源域数据集,箭头右侧数据集代表目标域数据集,且设定源域数据集数据是有标签数据,而目标域数据集数据是无标签数据。例如,在迁移故障诊断实验 A→B 中,数据集 A 为源域数据集,数据集 B 为目标域数据集。每次实验中,取全部源域数据和一半目标域数据作为

训练数据集,另一半目标域数据作为测试数据集。

表 1 迁移故障诊断实验
Table 1 Transfer fault diagnosis experiments

实验	A→B	B→A
训练数据	有标签数据集 A 50%数据集 B	有标签数据集 B 50%数据集 A
测试数据	剩余 50%数据集 B	剩余 50%数据集 A

实验中的模型参数设置如下。在状态识别模块中,根据文献[16],设置卷积故障诊断模块中的卷积核长度为5,池化长度为2。在领域适配模块中,计算最大均值差异的核函数选择RBF核函数。模型训练中,数据批量大小为256,其中一半来自于源域数据,一半来自于目标域数据。在上述参数设置下进行模型训练与测试并探索模型层数与惩罚项系数对迁移故障诊断结果的影响。设置模型层数为[8, 12, 16, 20]分别进行A→B和B→A的迁移故障诊断实验,每次实验重复15次,实验结果如图3所示。由图3可以看出,当模型参数为16时,取得了最好的迁移故障诊断结果。设置惩罚项系数为[0, 0.01, 0.5, 1, 10]与变化惩罚项系数 $2/(1 + \exp(-10 \times p)) - 1$,其中 p 是0~1之间的训练次数比值,重复15次A→B和B→A的迁移故障诊断实验,实验结果如图4所示。在所有的惩罚项系数中,变化惩罚项系数取得了最好的迁移故障诊断结果。因此,本文方法的故障诊断模块模型的层数取为16层,其中1个输入层,6个卷积层,6个池化层,2个全连接层和1个输出层。而模型训练过程中损失函数中的惩罚项系数随着训练次数的增加依次增大。




图 3 不同网络层数的迁移故障诊断识别率

Fig.3 Transfer fault diagnosis accuracies with different layers




图 4 不同惩罚项系数的迁移故障诊断识别率

Fig.4 Transfer fault diagnosis accuracies with different penalty coefficients

为验证提出算法的有效性,将本文算法与两种不同的故障诊断方法进行对比实验。基于不同的对比目的,对比故障诊断方法可分为以下两类:1)验证迁移算法对跨设备间故障诊断准确率的影响,将单一的状态识别模块作为对比方法用于跨设备间故障诊断实验。该方法为一维卷积神经网络,将原始振动信号输入一维卷积神经网络进行故障状态的识别。2)验证特征学习对于跨设备间故障诊断率的影响,将手动提取特征的迁移故障诊断方法作为对比方法用于跨设备间故障诊断实验。本文使用常用的浅层迁移故障诊断方法TCA^[17]作为对比方法进行迁移故障诊断实验。首先提取振动信号的时域、频域和时频域特征值,然后将提取的特征值进行TCA迁移学习,最后使用神经网络进行故障状态判定。

两种对比方法的迁移故障诊断结果如图5所示,由对比结果可以看出,1)提出方法的迁移故障诊断精度要大于没有迁移过程的深度卷积神经网络的迁移故障诊断精度,说明源域数据与目标域数据的特征知识的概率分布差异的度量与匹配迁移了数据特征知识,从而有效改善了跨设备间的故障诊断结果。2)相对于手动提取特征的迁移故障诊断方法,基于特征学习的方法取得了更好的迁移故障诊断结果。特征学习网络可学习振动信号所隐含的深层次特征知识,并且在深层特征空间内源域数据和目标域数据的特征知识差异性减小,从而有助于改善迁移故障诊断结果。




图 5 不同方法迁移故障诊断结果

Fig.5 Transfer fault diagnosis results with different methods

3.3 迁移结果可视化

为进一步验证迁移方法对于智能故障诊断准确率的影响机制,可视化不同领域数据的特征知识。以迁移故障诊断实验A→B为例,通过 t 分布随机邻近嵌入算法将源域数据A和目标域数据B的特征值映射为二维空间,然后在二维空间内可视化源域数据和目标域数据的特征值分布,如图6所示,分别可视化4个不同类型的数据特征分布。图6(a)为手动提取特征;图6(b)为手动提取特征并进行TCA特征迁移;图6(c)为原始信号学习特征但未进行特征学习;图6(d)为本文方法的特征。从图6中可以看出,相对于图6(a)~(c),图6(d)中源域数据

和目标域数据在3种故障状态下的特征分布更加容易区分。比如,图6(c)中源域数据和目标域数据的内圈故障数据特征分布在不同的空间位置,但是图6(d)中的源域数据和目标域数据的内圈故障数据特征分布在相似的空间位置,这种数据分布促进了判别模型的识别准确率。由此可以看出,本文方法在有效保证数据类别间可分性的同时匹配了不同域数据间的数据分布差异,从而可以提高迁移故障诊断的识别率。




图6 迁移结果可视化

Fig.6 Visualization of transfer fault diagnosis results

4 结 论

工业现场所采集数据多为无标签数据,这在一定程度上阻碍了智能故障诊断方法的工业化应用。为利用充足的实验室数据或者是相近设备多采集的监测数据进行智能模型训练并能进行工业现场应用,本文提出了一种无标签数据下基于特征知识迁移的机械设备智能故障方法。本文方法通过两个不同轴承实验台设备所采集的振动进行迁移故障诊断实验,在两个数据集上进行了与其他方法的对比实验并进行了结果可视化。由实验结果可知:1)由深度卷积神经网络所学习的深层隐含特征相对于手工提取特征具有更好的跨域泛化能力,可有效提升迁移故障诊断准确率;2)领域适配学习可匹配不同数据域之间特征知识空间内的分布差异,因此本文方法可有效提高迁移故障诊断识别率。上述实验与结论表明本文方法可一定程度解决无标签数据下机械设备的智能故障诊断问题,这为智能故障诊断方法的工业化应用提供了一种潜在可行的方案,有利于机械设备智能故障诊断的工业化应用。

参考文献

- [1] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
- LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [2] CERRADA M, ZURITA G, CABRERA D, et al, Fault diagnosis in spur gears based on genetic algorithm and random forest [j]. Mechanical Systems and Signal Processing, 2016, 70-71: 87-103.
- [3] SU Z Q, TANG B P, LIU Z R, et al, Multi-fault diagnosis for rotating machinery based on orthogonal supervised linear local tangent space alignment and least square support vector machine [J]. Neurocomputing, 2015, 157: 208-222.
- [4] JIA F, LEI Y G, GUO L, et al, A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines [J]. Neurocomputing, 2018, 272: 241-265.
- [5] LI CH, SÁNCHEZ R V, ZURITA G, et al. Fault diagnosis for rotating machinery using vibration measurement deep statistical feature learning [J]. Sensors, 2016, 16:895.
- [6] JING L Y, ZHAO M, LI P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement, 2017, 111: 1-10.
- [7] GUO L, LEI Y G, XING S B, 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): 7316-7326.
- [8] 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.
- [9] 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 Y G, YANG B, DU ZH J, et al. Deep transfer

- diagnosis method for machinery in big data era [J]. Journal of Mechanical Engineering, 2019, 55(7): 1-8.
- [10] PAN S J, YANG Q. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [11] BEN-DAVID S, BLITZER J, CRAMMER K, et al. A theory of learning from different domains [J]. Machine Learning, 2010, 79(1-2): 151-175.
- [12] 沈飞, 陈超, 严如强. 奇异值分解与迁移学习在电机故障诊断中的应用 [J]. 振动工程学报, 2017, 30(1): 118-126.
SHEN F, CHEN CH, YAN R Q. Application of SVD and transfer learning strategy on motor fault diagnosis [J]. Journal of Vibration Engineering, 2017, 30(1): 118-126.
- [13] 陈超, 沈飞, 严如强. 改进 LSSVM 迁移学习方法的轴承故障诊断 [J]. 仪器仪表学报, 2017, 38(1): 33-40.
CHEN CH, SHEN F, YAN R Q. Enhanced least squares support vector machine-based transfer learning strategy for bearing fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 33-40.
- [14] WEN L, GAO L, LI X Y. 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.
- [15] XIE J Y, ZHANG L B, DUAN L X, et al. On cross-domain feature fusion in gearbox fault diagnosis under various operating conditions based on transfer component analysis [C]. 2016 IEEE International Conference on Prognostics and Health Management (ICPHM), 2016: 1-6.
- [16] JIA F, LEI Y G, LU N, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization [J]. Mechanical Systems and Signal Processing, 2018, 110: 349-367.
- [17] PAN S J L, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis [J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.

作者简介



郭亮(通信作者), 2011 年和 2016 年于西南交通大学获得学士和博士学位。2016 年~2018 年在西安交通大学进行博士后研究工作。现为西南交通大学助理研究员, 主要研究方向为机械设备智能故障诊断和剩余寿命预测。

E-mail: guoliang@swjtu.edu.cn

Guo Liang (Corresponding author) received his B. Sc. and Ph. D. degrees in mechanical engineering from Southwest Jiaotong University in 2011 and 2016, respectively, he was a postdoctoral research fellow at Xi'an Jiaotong University from 2016 to 2018. He is currently an assistant professor at Southwest Jiaotong University. His research interests include machinery intelligent fault diagnostics, and remaining useful life prediction.