DOI: 10.3901/JME.2019.07.001

大数据下机械装备故障的深度迁移诊断方法^{*}

雷亚国 杨 彬 杜兆钧 吕 娜

(西安交通大学现代设计及转子轴承系统教育部重点实验室 西安 710049)

摘要: 机械故障智能诊断是大数据驱动下保障装备安全运行的重要手段。为准确识别装备的健康状态,智能诊断需要依靠充足的可用监测数据训练智能诊断模型。而在工程实际中,机械装备的可用数据稀缺,导致训练的智能诊断模型对装备健康状态的识别精度低,制约了机械故障智能诊断的工程应用。鉴于实验室环境中获取的装备可用数据充足,即数据的典型故障信息丰富、健康标记信息充足,且此类数据与工程实际装备的监测数据间存在相关的故障信息,提出机械装备故障的深度迁移诊断方法,将实验室环境中积累的故障诊断知识迁移应用于工程实际装备。首先构建领域共享的深度残差网络,从源自不同机械装备的监测数据中提取迁移故障特征;然后在深度残差网络的训练过程中施加领域适配正则项约束,形成深度迁移诊断模型。通过实验室滚动轴承与机车轴承的迁移诊断试验对提出方法进行验证,试验结果表明:提出方法能够运用实验室滚动轴承的故障诊断知识,识别出机车轴承的健康状态。

关键词: 机械装备;机械故障智能诊断;深度学习;迁移学习

中图分类号: TH17

Deep Transfer Diagnosis Method for Machinery in Big Data Era

LEI Yaguo YANG Bin DU Zhaojun LÜ Na

(Key Laboratory of Education Ministry for Modern Design and Rotor-Bearing System,
Xi'an Jiaotong University, Xi'an 710049)

Abstract: In the era of big data, intelligent fault diagnosis is an important tool to guarantee the healthy operation of the machinery. In order to accurately identify the health states of the machinery, it is necessary for intelligent fault diagnosis to collect massive available data and then train an intelligent diagnosis model. In real cases, however, there is no sufficient available data to train a fault diagnosis model with high diagnosis accuracy, which limits the engineering application of intelligent fault diagnosis. Fortunately, the data collected from the laboratory machines have sufficient typical fault information and label information. These data also have related fault information to the collected data from the real-case machines. Therefore, a deep transfer diagnosis method is proposed to identify the health states of the real-case machines by using the fault diagnosis knowledge from the laboratory machines. In the proposed method, the domain-shared deep residual networks are first used to extract transferable features of the collected data from different machines. Then, the regularization terms of domain adaptation are introduced into the training process of the deep residual networks so as to establish a deep transfer diagnosis model. The proposed method is verified by a transfer diagnosis case from the laboratory bearings to the locomotive bearings. The results show that the proposed method is able to use the fault diagnosis knowledge from the laboratory bearings to identify the health states of the locomotive bearings.

Key words: machinery; intelligent fault diagnosis; deep learning; transfer learning

0 前言

随着工业互联网、物联网技术的快速兴起与蓬勃发展,机械装备的多源传感器网络密集排布、监测数据交互量与日俱增,使机械故障诊断步入“大

数据”时代,这为全面掌握装备的健康服役状态提供了大信息、大知识,而如何有效挖掘机械大数据背后的潜在价值成为大数据驱动下保障装备安全运行的前沿热点与研究难点^[1]。

故障智能诊断通过自动提取机械监测数据中隐含的故障信息,智能识别装备的健康状态,成为大数据下保障机械装备安全运行的重要手段。近年来,涉及机械故障智能诊断的相关研究层出不穷^[2-4],然而,这些研究一般基于可用监测数据充足的假设,

^{*} 国家自然科学基金(61673311)、NSFC-浙江两化融合联合基金(U1709208)和中组部“万人计划”青年拔尖人才支持计划资助项目。20180629 收到初稿,20181107 收到修改稿

即要求用于智能诊断模型训练的机械监测数据：典型故障信息丰富、健康标记信息充足。在工程实际中，上述假设却很难满足，原因在于工程实际装备的监测数据具有如下特点：① 价值密度低，装备长期处于正常的运行状态，因此，正常状态下获取的监测数据多，而故障状态下获取的监测数据少，使得监测数据中的信息重复性高、典型故障信息缺失；② 可利用率低，装备在长期运行过程中，积累了海量监测数据，但其中仅有极少数监测数据对应的装备健康状态已知，可用于训练智能诊断模型。多数监测数据需要标记健康状态，而标记数据代价高昂，如不可频繁停机自检故障、人工标记数据费时费力，致使监测数据的健康标记信息匮乏。综上所述，工程实际中获取的机械装备可用数据稀缺，难以训练并获得对装备健康状态识别精度高的智能诊断模型。研究和利用先进的新理论和新技术解决可用数据稀缺这一问题，是机械故障智能诊断的研究成果向工程应用转化的关键所在。

近年来，迁移学习受到国内外学者的广泛关注与研究。根据《中国机器学习白皮书》定义^[5]：迁移学习是运用已存有的知识对不同但相关领域问题进行求解的一种新的机器学习方法。该技术能够解决可用训练样本稀疏的学习问题，并已经在图像识别^[6]、语音识别^[7]、文本识别^[8]等领域成功应用。在机械故障智能诊断领域，迁移学习逐渐开始受到研究人员的关注。陈超等^[9]提出基于辅助数据的改进LSSVM迁移学习策略，弥补了不同工况下轴承可用数据不足的缺陷，提高了轴承故障的诊断精度；LU等^[10]建立领域适配智能诊断模型，实现了不同工况之间滚动轴承的健康状态识别。上述研究成果表明：① 利用已有机械的故障诊断知识能够识别具有相关故障信息机械的健康状态；② 缩小因变工况、不同测试环境等因素引入的数据分布差异是迁移学习应用于故障智能诊断的关键。然而，以上研究均局限于同一机械装备在不同运行工况间的迁移诊断任务，其方法的有效性建立在一定假设下：同一装备在某一工况下获取的可用数据充足，这与工程实际装备的监测数据特点不符，难以适应和满足机械故障智能诊断的工程应用需求。

针对以上不足，本文考虑到实验室环境中，机械装备的监测数据具有典型故障信息丰富、健康标记信息充足的特点，且此类数据与工程实际装备的监测数据间存在相关故障信息，若能取实验室中试验装备的监测数据之“长”弥补工程实际装备的监测数据之“短”，则可望放宽可用数据充足的假设对机械故障智能诊断研究的限制。因此，提出机械装

备故障的深度迁移诊断方法。该方法通过构建领域共享的深度残差网络，提取源自试验装备与工程实际装备监测数据中的迁移故障特征，并在深度残差网络的训练过程中引入领域适配约束，形成深度迁移诊断模型。旨在：① 利用试验装备监测数据中丰富的典型故障信息，弥补工程实际装备监测数据的典型故障信息缺失；② 运用试验装备充足的可用样本辅助训练智能诊断模型，克服工程实际装备的监测数据因健康标记信息匮乏而导致训练的模型对装备健康状态识别精度低的缺陷。最终通过迁移实验室环境中积累的故障诊断知识，识别出工程实际装备的健康状态。

1 迁移诊断问题描述

假设在实验室环境中，通过机械装备的故障模拟试验可获得监测数据集 $\{\mathbf{x}_i^s, \mathbf{y}_i^s\}_{i=1}^{n_s}$ ，包含 n_s 个样例。 $\mathbf{y}_i^s \in \mathcal{Y}$ 为样本 $\mathbf{x}_i^s$ 的健康标记， $\mathcal{Y} = \{1, 2, \dots, k\}$ 为标记空间，含有 k 个健康状态。样本 $\mathbf{x}_i^s$ 属于样本空间 $\mathcal{X}^s$ ，数据生成服从边缘概率分布 $P(\mathcal{X}^s)$ 。在工程实际中，获取的装备健康监测数据集 $\{\mathbf{x}_i^t\}_{i=1}^{n_t}$ ，其中包含 n_t 个待识别健康状态的样本。由于试验装备与工程实际装备的服役环境、作业工况乃至规格型号等均有不同，因此，两者监测数据的生成机制存在较大差异，从统计分析角度可描述为：工程实际装备的监测数据 $\mathbf{x}_i^t \in \mathcal{X}^t$ 服从边缘概率分布 $Q(\mathcal{X}^t)$ ，且 $Q \neq P$ 。

结合迁移学习的相关概念及术语^[11]，本文涉及的机械故障迁移诊断问题应满足以下条件。

(1) 源域 $\mathcal{D}^s$ 由含健康标记信息的试验装备监测数据的样本空间 $\mathcal{X}^s$ 及其服从的数据分布 $P(\mathcal{X}^s)$ 组成，即： $\mathcal{D}^s = \{\mathcal{X}^s, P(\mathcal{X}^s)\}$ ，为识别工程实际装备的健康状态提供所需的故障诊断知识。

(2) 目标域 $\mathcal{D}^t$ 由无健康标记信息的工程实际装备监测数据的样本空间 $\mathcal{X}^t$ 及其服从的数据分布 $P(\mathcal{X}^t)$ 组成，即： $\mathcal{D}^t = \{\mathcal{X}^t, P(\mathcal{X}^t)\}$ ，是实验室中试验装备的故障诊断知识的应用对象。

(3) 源域与目标域之间应具有相关的典型故障信息，且源域须满足目标域的故障诊断知识需要。要求源域数据的标记空间 $\mathcal{Y}^s$ 须涵盖目标域数据的标记空间 $\mathcal{Y}^t$ ，即： $\mathcal{Y}^t \subseteq \mathcal{Y}^s \subseteq \mathcal{Y}$ 。

通过源域装备的监测数据样本训练，建立由源域装备监测数据的样本空间 $\mathcal{X}^s$ 至健康标记空间 $\mathcal{Y}^s$ 的非线性映射关系 $f: \mathcal{X}^s \mapsto \mathcal{Y}^s$ ，即为获取的装备故障诊断知识。如图1a所示，由于源域与目标域装备的监测数据之间存在较大的分布差异，源域装备的

故障诊断知识 f 不能准确识别目标域装备的无健康标记样本类别, 导致误判机械装备的健康状态。针对上述的领域差异问题, 如图 1b 所示, 本文旨在构建深度迁移诊断模型, 适配源域与目标域装备的监测数据分布, 使源域装备的故障诊断知识 f 能够识别目标域装备的健康状态。

图 1 机械故障迁移诊断示意图

2 机械故障的深度迁移诊断方法

针对由试验装备故障至工程实际装备故障的迁移诊断问题, 建立机械故障的深度迁移诊断方法, 该方法主要由迁移故障特征提取及其分布适配两部分组成。其中, 前者利用领域共享的深度残差网络 (Deep residual network, ResNet), 提取源域与目标域装备监测数据中的迁移故障特征; 后者通过正则化约束 ResNet 的训练过程, 形成机械故障的深度迁移诊断模型, 缩小提取的源域与目标域装备监测数据中迁移故障特征间的分布差异, 使源域装备的故障诊断知识能够用于识别目标域装备的健康状态。

2.1 迁移故障特征提取

构建的 ResNet 模型结构如图 2 所示, 主要由输入层、多级残差单元、全连接层及输出层四部分组成。该模型能够同时提取源域与目标域装备监测数据中的迁移故障特征。

若 $\mathbf{x}_i^s$ 、 $\mathbf{x}_i^t$ 分别为源域与目标域装备监测数据集中的第 i 个样本。计算卷积核 $\mathbf{k}^{\text{inp}} \in \mathbf{R}^{128 \times 1 \times 20}$ 与输入的样本 $\mathbf{x}_i^{\text{inp}} = \{\mathbf{x}_i^s, \mathbf{x}_i^t\}$ 的卷积和, 可得特征矢量

$$\mathbf{x}_i^{\text{inp}} = f(\mathbf{x}_i^{\text{inp}}; \boldsymbol{\theta}^{\text{inp}}) = \sigma_r(\mathbf{x}_i^{\text{inp}} * \mathbf{k}^{\text{inp}} + \mathbf{b}^{\text{inp}}) \quad (1)$$

式中, $\boldsymbol{\theta}^{\text{inp}} = \{\mathbf{k}^{\text{inp}}, \mathbf{b}^{\text{inp}}\}$ 为输入层待训练参数集。

为降低特征维数, 减少 ResNet 的待训练参数数量, 将特征矢量 $\mathbf{x}_i^{\text{inp}}$ 分割为若干无重叠段, 返回每段元素的最大值, 即最大池化过程, 由此可得

$$(\mathbf{v}_i^{\text{inp}})_{m,n} = \max \left\{ \mathbf{x}_{(i),j,n}^{\text{inp}} \mid s(m-1)+1 \leq j \leq sm \right\} \quad (2)$$

式中, $\mathbf{x}_{(i),j,n}^{\text{inp}}$ 为特征矢量 $\mathbf{x}_i^{\text{inp}}$ 中第 j 行、 n 列元素; s 为无重叠段长度, 此处取 $s=2$ 。

图 2 ResNet 的模型结构

ResNet 通过堆叠多级残差单元, 提取池化后特征的深层抽象表达。每级残差单元均为残差函数与输入特征之和^[12], 其中, 残差函数为堆叠两层卷积层构建的非线性映射 $F: \mathbf{x} \mapsto F(\mathbf{x})$, 即

$$F(\mathbf{x}_i^{\text{inp}, l-1}; \boldsymbol{\theta}^l) = [\sigma_r(\mathbf{x}_i^{\text{inp}, l-1} * \mathbf{k}^{l,1} + \mathbf{b}^{l,1})] * \mathbf{k}^{l,2} + \mathbf{b}^{l,2} \quad (3)$$

式中, $\boldsymbol{\theta}^l = \{\mathbf{k}^{l,j}, \mathbf{b}^{l,j}\}_{j=1}^2$ 为第 l 级残差单元的待训练参数集; $F(\mathbf{x}_i^{\text{inp}, l-1}; \boldsymbol{\theta}^l)$ 表示第 l 级的残差函数。

令 $\mathbf{x}_i^{\text{inp}, 0} = \mathbf{v}_i^{\text{inp}}$, 可得第 l 级残差单元的输出为

$$\mathbf{x}_i^{\text{inp}, l} = \sigma_r[F(\mathbf{x}_i^{\text{inp}, l-1}; \boldsymbol{\theta}^l) + \mathbf{x}_i^{\text{inp}, l-1}] \quad l=1, 2, \dots, L \quad (4)$$

式中, L 为残差单元的级数, 此处取 $L=12$ 。

获得源域与目标域装备监测数据的迁移故障特征 $\mathbf{x}_i^{\text{inp}, L}$ 后, 再次进行最大池化, 并将池化后的特征矢量平铺为一维矢量, 以此作为全连接层的输入

$$\mathbf{x}_i^{\text{inp}, F_1} = \text{flatten}[\text{down}(\mathbf{x}_i^{\text{inp}, L}, s)] \quad (5)$$

式中, $\text{flatten}(\cdot)$ 为平铺函数; $\text{down}(\cdot)$ 详见式(2)。

通过全连接层将提取的迁移故障特征映射至样本的标记空间。如图 2 所示, 全连接层为单隐层全连接网络, 其中, 隐层 F_2 的输出为

$$\mathbf{x}_i^{\text{inp}, F_2} = g(\mathbf{x}_i^{\text{inp}, F_1}; \boldsymbol{\theta}^{F_2}) = \sigma_r(\mathbf{w}^{F_2} \cdot \mathbf{x}_i^{\text{inp}, F_1} + \mathbf{b}^{F_2}) \quad (6)$$

式中, $\boldsymbol{\theta}^{F_2} = \{\mathbf{w}^{F_2}, \mathbf{b}^{F_2}\}$ 为 F_2 层的待训练参数集。

在输出层 F_3 中引入 Softmax 函数, 预测样本 $\mathbf{x}_i^{\text{inp}} = \{\mathbf{x}_i^s, \mathbf{x}_i^t\}$ 在标记空间的概率分布, 则第 i 个监测数据样本属于第 q 个健康状态的概率为

$$P(y_i^{\mathcal{D}} = q | \mathbf{x}_i^{\mathcal{D}, F_2}; \boldsymbol{\theta}^{F_3}) = \frac{\exp(\mathbf{w}_q^{F_3} \cdot \mathbf{x}_i^{\mathcal{D}, F_2} + \mathbf{b}_q^{F_3})}{\sum_{q=1}^k \exp(\mathbf{w}_q^{F_3} \cdot \mathbf{x}_i^{\mathcal{D}, F_2} + \mathbf{b}_q^{F_3})} \quad (7)$$

式中, $\boldsymbol{\theta}^{F_3} = \{\mathbf{w}^{F_3}, \mathbf{b}^{F_3}\}$ 为输出层 F_3 的待训练参数集。

2.2 迁移故障特征的分布适配

源域与目标域装备的监测数据来源于不同的机械装备, 导致 ResNet 从数据中提取的迁移故障特征亦具有较大分布差异。此外, 由于目标域的数据样本无健康标记信息, 无法训练 ResNet 的输出层待训练参数集 $\boldsymbol{\theta}^{F_3}$ 。因此, 分别从迁移故障特征的边缘概率分布适配以及条件概率分布适配两方面入手, 缩小源域与目标域的差异。

(1) 边缘概率分布适配。

最大均值差异(Maximum mean discrepancy, MMD)是衡量两数据集分布差异的非参数距离指标^[13]。源域与目标域装备的监测数据样本通过 ResNet 深层表征后, 其迁移故障特征的分布差异滞留全连接层^[14]。假设迁移故障特征集合为 F^s 、 F^t , 则存在再生核希尔伯特空间 $\mathcal{H}$ (Reproducing kernel Hilbert space, RKHS), 有映射函数 $\Phi(\cdot) \in \mathcal{H}$ 将迁移故障特征由原特征空间投影至 RKHS。因此, 源域与目标域迁移故障特征之间的 MMD 可定义为

$$D_{\mathcal{H}}(F^s, F^t) := \sup_{\Phi \in \mathcal{H}} \left\{ E[\Phi(\mathbf{x}_i^{s, F_2})] - E[\Phi(\mathbf{x}_i^{t, F_2})] \right\} \quad (8)$$

式中, $\sup\{\cdot\}$ 为集合上确界。

由式(8)可知, 在完备的 RKHS 中总存在映射 $\Phi^*(\cdot)$ 使得源域与目标域迁移故障特征间的均值距离达到集合的最小上界。基于高斯核函数构造 RKHS, 则 MMD 的经验估计可表达为

$$D_{\mathcal{H}}^2(F^s, F^t) = \frac{1}{n_s^2} \sum_{i=1}^{n_s} \sum_{j=1}^{n_s} k(\mathbf{x}_i^{s, F_2}, \mathbf{x}_j^{s, F_2}) - \frac{2}{n_s n_t} \sum_{i=1}^{n_s} \sum_{j=1}^{n_t} k(\mathbf{x}_i^{s, F_2}, \mathbf{x}_j^{t, F_2}) + \frac{1}{n_t^2} \sum_{i=1}^{n_t} \sum_{j=1}^{n_t} k(\mathbf{x}_i^{t, F_2}, \mathbf{x}_j^{t, F_2}) \quad (9)$$

式中, $k(\cdot, \cdot)$ 为高斯核函数, 核宽度为 σ 。核宽度 σ 取值不同, MMD 的估计值大小不同, 影响了 MMD 在领域适配中的实际应用。引入多核植入的高斯核函数, 将传统核参数选择的问题转换为多核核函数的凸优化问题^[13, 15]。假设多核高斯核函数集为

$$\mathcal{K} := \left\{ k := \sum_{u=1}^U \beta_u k_u \mid \sum_{u=1}^U \beta_u = 1, \beta_u \geq 0 \right\} \quad (10)$$

由式(10)可知, 函数集 $\mathcal{K}$ 是 U 个核宽度不同的高斯核函数的凸组合, $\{\beta_u\}_{u=1}^U$ 为凸优化参数集。求解最优值 $\{\beta_u^*\}_{u=1}^U$, 使得构造函数

$$\mathcal{F}(\beta_u) = \frac{\sum_{u=1}^U \beta_u k_u}{\frac{1}{U} \sum_{u=1}^U \left(\beta_u k_u - \frac{1}{U} \sum_{u=1}^U \beta_u k_u \right)^2} \quad k_u \in \mathcal{K} \quad (11)$$

取得最大值, 即存在如下凸优化问题

$$\begin{aligned} & \max_{\beta_u} \mathcal{F}(\beta_u) \\ & \text{s.t.} \quad \sum_{u=1}^U \beta_u = 1 \quad \beta_u \geq 0 \end{aligned} \quad (12)$$

综上, 通过最大最小化式(9), 可适配迁移故障特征的边缘概率分布, 即存在如下优化问题

$$\min_{\boldsymbol{\theta}^{\text{inp}}, \boldsymbol{\theta}', \boldsymbol{\theta}^{F_2}} \max_{k_u \in \mathcal{K}} D_{\mathcal{H}}^2(F^s, F^t) \quad (13)$$

(2) 条件概率分布适配。

伪标记学习将 ResNet 预测的样本健康标记赋予该无标记样本, 使无健康标记信息的机械监测数据具备监督训练智能诊断模型的能力^[16]。伪标记学习由样本标记预测与伪标记生成两部分组成。

由式(7)可知, Softmax 函数能够输出无标记样本在标记空间内的概率分布。若源域与目标域装备的样本空间均含有 k 种机械健康状态, 则样本 $\mathbf{x}_i^{\mathcal{D}}$ 的预测标记的概率分布 $\mathcal{P}_i^{\mathcal{D}, F_3}$ 为

$$\mathcal{P}_i^{\mathcal{D}, F_3} = \left[P(y_i^{\mathcal{D}} = 1 | \mathbf{x}_i^{\mathcal{D}, F_2}) \cdots P(y_i^{\mathcal{D}} = k | \mathbf{x}_i^{\mathcal{D}, F_2}) \right]^T \quad (14)$$

根据式(14)可预测目标域样本 $\mathbf{x}_i^t$ 健康标记的概率分布, 并生成该样本的伪标记, 即为

$$\begin{aligned} \hat{\mathbf{y}}_i^t &= [\hat{y}_1^t \quad \hat{y}_2^t \quad \cdots \quad \hat{y}_j^t \quad \cdots \quad \hat{y}_k^t] \\ \hat{y}_j^t &= \begin{cases} 1 & j = \arg \max_j \mathcal{P}_i^{t, F_3} \\ 0 & \text{其余} \end{cases} \end{aligned} \quad (15)$$

式中, $\hat{\mathbf{y}}_i^t$ 为目标域样本 $\mathbf{x}_i^t$ 的二值化伪标记。

综上, 伪标记学习借助源域样本训练所得的 ResNet, 赋予目标域样本预测的健康标记, 使目标域和源域装备的样本能够同时监督训练 ResNet, 实现源域与目标域装备的迁移故障特征向同一标记空间映射, 以达到适配条件概率分布的目的。因此, 伪标记学习存在如下优化问题

$$\min_{\boldsymbol{\theta}} \frac{1}{n_s} \sum_{i=1}^{n_s} \mathcal{T}(\mathbf{y}_i^s, \mathcal{P}_i^{s, F_3}) + \alpha \frac{1}{n_t} \sum_{j=1}^{n_t} \mathcal{T}(\hat{\mathbf{y}}_j^t, \mathcal{P}_j^{t, F_3}) \quad (16)$$

式中, $\boldsymbol{\theta} = \{\boldsymbol{\theta}^{\text{inp}}, \boldsymbol{\theta}', \boldsymbol{\theta}^{F_2}, \boldsymbol{\theta}^{F_3}\}$ 为 ResNet 的待训练参数集; $\mathbf{y}_i^s$ 为源域样本 $\mathbf{x}_i^s$ 的二值化标记; $\mathcal{T}(\cdot, \cdot)$ 为代价函数, 此处取交叉熵代价函数衡量样本预测标记与真实标记的差异; α 为伪标记正则项的惩罚因子。

2.3 迁移诊断模型的训练

为提高目标域装备健康状态的识别精度, 完成迁移诊断任务, 本文结合式(13)与式(16)所示的优化问题, 构建如下用于迁移诊断模型训练的目标函数

$$\min_{\theta} \max_{k_u \in \mathcal{K}} \underbrace{-\frac{1}{n} \sum_{i=1}^n (y_i^s)^T \cdot \ln(\mathcal{P}_i^{s, F_3})}_{\text{源域样本交叉熵损失}} - \underbrace{\alpha \frac{1}{n} \sum_{j=1}^n (\hat{y}_j^t)^T \cdot \ln(\mathcal{P}_j^{t, F_3})}_{\text{目标域样本交叉熵损失}} + \underbrace{\lambda D_{\mathcal{H}}^2(F^s, F^t)}_{\text{迁移特征分布适配}} \quad (17)$$

式中, n 为最小批训练样本个数; λ 为边缘概率分布适配正则项的惩罚因子。

由式(17)可知构建的迁移诊断模型的目标函数由三部分组成: ① 最小化源域装备监测数据的预测标记与真实标记之间的交叉熵损失; ② 最小化目标域装备监测数据的预测标记与伪标记之间的交叉熵损失; ③ 最大最小化源域与目标域装备的迁移故障特征之间的 MMD 估计值。该目标函数的优化可归纳为如下步骤。

(1) 初始化: 给定源域装备的含标记监测数据集 $\{(\mathbf{x}_i^s, y_i^s)\}_{i=1}^n$ 与目标域装备的监测数据集 $\{\mathbf{x}_i^t\}_{i=1}^n$; 随机初始化迁移诊断模型的待训练参数集 θ ; 令 $\{\beta_u\}_{u=1}^U = [1/U]_{U \times 1}$; 设置惩罚因子 $\{\alpha, \lambda\}$ 。

(2) 前向传播: ① 执行式(1)~(6), 逐层提取源域与目标域装备监测数据中的迁移故障特征; ② 执行式(9)计算多核植入的 MMD 估计值; ③ 分析式(12)所示的凸优化问题, 并求解最优解集 $\{\beta_u^*\}_{u=1}^U$, 再结合 $\{\beta_u^*\}_{u=1}^U$ 计算 MMD 估计值; ④ 执行式(7)预测目标域装备数据的健康标记的概率分布; ⑤ 结合式(15)生成目标域监测数据的伪标记; ⑥ 执行式(17)计算迁移诊断模型的目标函数值, 若该值大于设定阈值 ε , 则执行步骤(3), 反之执行步骤(4)。

(3) 反向传播: ① 采用 Adam 优化算法, 反向逐层更新待训练参数集 θ ; ② 返回执行步骤(2)。

(4) 装备健康状态识别: 保存待训练参数集 θ , 输入目标域装备的监测数据集 $\{\mathbf{x}_i^t\}_{i=1}^n$, 返回 F_3 层的输出结果, 即预测的样本健康标记的概率分布, 概率分布中元素最大值对应的健康标记即代表预测的目标域装备健康状态。

3 试验验证

机车滚动轴承是机车轮对的关键部件, 其健康

服役对保障机车的安全运行至关重要。在工程实际中, 获取的机车轴承监测数据具有典型故障信息缺失、健康标记信息匮乏的特点, 难以训练对轴承健康状态识别精度高的智能诊断模型。本文利用实验室滚动轴承故障模拟试验中获取的数据集, 辅助训练迁移诊断模型, 使之能够识别机车滚动轴承的健康状态, 并对提出方法进行验证。

3.1 迁移诊断数据集

选用的迁移诊断数据集由 3 个滚动轴承数据集组成, 包括: 实验室齿轮箱轴承数据集 A、实验室电动机轴承数据集 B 及机车滚动轴承故障数据集 C。该迁移诊断数据集的详细信息见表 1。

表 1 迁移诊断数据集详细信息

滚动轴承数据集	轴承型号	健康状态	样本数
试验轴承数据集 A	LDK UER204	正常	1 088 (272×4)
		内圈故障	
		外圈故障	
		滚动体故障	
试验轴承数据集 B	SKF6205	正常	1 088 (272×4)
		内圈故障	
		外圈故障	
		滚动体故障	
机车轴承数据集 C	552732QT	正常	1 088 (272×4)
		内圈磨损	
		外圈磨损	
		滚动体磨损	

数据集 A 源自多级齿轮传动试验台, 该试验台主要由电动机、定轴齿轮箱、行星齿轮箱等组成。数据集的振动样本采自定轴齿轮箱的 LDK UER204 型滚动轴承, 包括正常状态、内圈故障、外圈故障及滚动体故障四种健康状态。每种健康状态的振动样本在电动机转速 1 200 r/min、空载下采集, 采样频率为 12.8 kHz。数据集共有振动样本 1 088 个, 每种轴承健康状态的振动样本为 272 个。

数据集 B 来自美国凯斯西储大学的轴承数据中心。该数据集集中的振动样本采自电动机驱动轴的 SKF6205 型滚动轴承, 包括正常状态及损伤直径为 0.355 6 mm 的内圈故障、外圈故障、滚动体故障四种健康状态。每种健康状态的轴承监测数据在不同负载(0 HP、1 HP、2 HP、3 HP)下采集, 采样频率设置为 12 kHz。数据集共有振动样本 1 088 个, 每种轴承健康状态在单一工况下的样本为 68 个。

数据集 C 源自机车轮对的 552732QT 型滚动轴承。该数据集包括正常状态、内圈磨损、外圈磨损及滚动体磨损四种健康状态下的振动样本, 每种健康状态的振动样本在转速 500 r/min、径向负载 9 800

N下采集, 采样频率设置为 12.8 kHz。数据集共有样本 1 088 个, 每种健康状态的振动样本为 272 个。

综上, 结合本文所涉及的机械故障迁移诊断问题, 创建迁移诊断任务 $A \rightarrow C$ 与 $B \rightarrow C$ 对提出方法进行验证。为模拟机车轴承监测数据存在的可用数据稀缺的问题, 假设在迁移诊断模型的训练过程中, 数据集 C 中的样本无健康标记信息。

3.2 迁移诊断结果

通过迁移诊断数据集训练模型, 使实验室轴承的故障诊断知识能够识别机车轴承的健康状态。在迁移诊断模型的训练过程中, 提出方法的主要参数设置如下: 植入核宽度为 $[10^{-3}, 10^{-2}, 10^{-1}, 1, 10, 10^2, 10^3, 10^4]$ 的多核核函数; λ 取值范围为 $[0.1, 1, 10, 100, 1\ 000]$; α 取值范围为 $[0.01, 0.05, 0.1, 0.5, 1]$ 。选择使迁移诊断模型的目标函数取得最小值时的参数 λ 与 α 为最优参数组合。为减小随机初始化待训练参数对提出方法的迁移诊断结果的影响, 重复验证 50 次, 统计结果如图 3 所示。针对迁移诊断任务 $A \rightarrow C$, 提出方法对机车轴承健康状态, 即数据集 C 中样本的迁移诊断精度为 76.85%, 标准差为 3.74%。对于迁移诊断任务 $B \rightarrow C$, 提出方法的迁移诊断精度为 86.91%, 标准差为 1.91%。由此可知: 即使在机车轴承的监测数据无健康标记信息时, 提出方法仍能在一定程度上利用实验室轴承的故障诊断知识识别其对应的健康状态。

为进一步说明提出方法的优势, 对比分析了提出方法与如下 3 种方法的迁移结果, 如图 3 所示。

图3 迁移诊断结果对比图

(1) 普通 ResNet。该方法与提出方法具有相同的结构参数, 但缺少迁移故障特征的分布适配过程。针对迁移诊断任务 $A \rightarrow C$, 该方法对机车轴承健康状态的识别精度为 28.88%, 标准差为 3.01%。对于迁移诊断任务 $B \rightarrow C$, 该方法对机车轴承的健

康状态识别精度为 55.78%, 标准差为 12.23%。结果表明: 基于普通 ResNet 的智能诊断模型对机车轴承健康状态的识别精度不高, 究其原因是实验室轴承与机车轴承的监测数据集间存在显著的分布差异。

(2) 文献[17]提出的迁移成分分析(Transfer component analysis, TCA)。TCA 以轴承监测数据的幅值谱作为输入, 将实验室轴承与机车轴承的监测数据降维映射至同一特征空间, 并在此空间内最小化两类轴承监测数据集间的距离。对于迁移诊断任务 $A \rightarrow C$, 该方法对机车轴承健康状态的迁移诊断精度为 25%。而对于任务 $B \rightarrow C$, 该方法的迁移诊断精度为 44.12%。相较于普通 ResNet 及提出方法, TCA 的迁移诊断精度较低, 究其原因是 TCA 缺乏深层提取迁移故障特征的能力。

(3) 文献[10]提出的领域适配智能诊断模型。该方法以轴承监测数据的幅值谱为输入, 利用单隐层自编码器提取实验室轴承与机车轴承监测数据的迁移故障特征, 并在模型训练过程中适配迁移故障特征的边缘概率分布。对于迁移诊断任务 $A \rightarrow C$, 该方法对机车轴承健康状态的迁移诊断精度为 41.04%, 标准差为 3.31%。对于迁移诊断任务 $B \rightarrow C$, 该方法的迁移诊断精度为 56.35%, 标准差为 1.74%。对比提出方法的迁移诊断结果可知: 提出方法具有更高的自动化程度与迁移诊断精度。其一方面能够直接从时域振动样本中提取更深层的迁移故障特征, 略去了时域振动样本向频域幅值谱样本的转换过程。另一方面在适配迁移故障特征的边缘概率分布的基础上, 增加条件概率分布适配过程。

为直观分析提出方法的有效性, 利用 t-分布邻域嵌入(t-distribution stochastic neighbor embedding, t-SNE)算法将提取的故障特征(F_2 层输出)降维至二维平面, 并以散点图呈现, 如图 4 与图 5 所示。由图 4 所示普通 ResNet 的深层故障特征散点图可知: 利用实验室轴承的监测数据, 即数据集 A 与数据集 B 训练的普通 ResNet 智能诊断模型, 仅能提取实验室轴承数据中的深层故障特征, 而当该模型直接用于识别机车轴承监测数据, 即数据集 C 中样本的健康状态时, 由于提取的机车轴承故障特征与实验室轴承故障特征间存在较大分布差异, 使得实验室轴承的故障诊断知识, 即训练的诊断模型无法识别机车轴承的无健康标记样本。根据图 5 所示提出方法的迁移故障特征散点图可知: 提出方法在缩小实验室轴承与机车轴承迁移故障特征间的分布差异的同时, 增大了机车轴承故障特征的类型距离, 使得训练的迁移诊断模型对机车轴承监测数据样本的辨识

度提高。对比图 4 与图 5 所示的故障特征分布可知：提出方法通过领域适配，将迁移故障特征的分布由实验室轴承向机车轴承迁移，放大了实验室轴承与机车轴承的监测数据中隐含的相似故障信息，而抑制了差异性信息对轴承故障智能诊断过程的影响，使得实验室轴承的故障诊断知识能够识别机车轴承的健康状态，直观地解释了提出方法的有效性。

图 4 普通 ResNet 的深层故障特征散点图

图 5 提出方法的迁移故障特征散点图

4 结论

本文利用实验室环境中积累的故障诊断知识，解决了工程实际装备因可用数据稀缺而导致训练的智能诊断模型对装备健康状态识别精度低的实际问题，并得出以下结论。

(1) 提出机械装备故障的深度迁移诊断方法。该方法即使在工程实际装备的监测数据无健康标记信息，且难以有效训练智能诊断模型时，仍能迁移试验装备的故障诊断知识识别工程实际装备的健康状态。并相较于同类方法，提出方法的诊断精度显著提高。

(2) 提出方法将数据分布作为迁移机械装备故障诊断知识的桥梁。通过提取试验装备与工程实际装备监测数据中具有相似分布的迁移故障特征，使实验室环境中积累的故障诊断知识能够识别工程实际装备的健康状态。

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 Yaguo, JIA Feng, KONG Detong, 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] LEI Yaguo. Intelligent fault diagnosis and remaining useful life prediction of rotation machinery[M]. Oxford: Elsevier Butterworth-Heinemann, 2016.
- [3] KHAN S, YAIRI T. A review on the application of deep learning in system health management[J]. Mechanical Systems and Signal Processing, 2018, 107: 241-265.
- [4] 雷亚国, 何正嘉. 混合智能故障诊断与预示技术的应用进展[J]. 振动与冲击, 2011, 30(9): 129-135.
LEI Yaguo, HE Zhengjia. Advances in applications of hybrid intelligent fault diagnosis and prognosis technique[J]. Journal of Vibration and Shock, 2011, 30(9): 129-135.
- [5] 中国人工智能学会. 中国机器学习白皮书[EB/OL]. [2016-01-09]. <http://www.caai.cn/index.php?s=/Home/File/download/id/24.html>.
Chinese Association for Artificial Intelligence. White paper on Chinese machine learning[EB/OL]. [2016-01-09]. <http://www.caai.cn/index.php?s=/Home/File/download/id/24.html>.
- [6] ZHANG Lei, ZUO Wangmeng, ZHANG D. LSST latent sparse domain transfer learning for visual adaptation[J]. IEEE Transactions on Image Process, 2016, 25(3):

- 1177-1191.
- [7] DENG Jun, XU Xinzhou, ZHANG Zixing, et al. Universum autoencoder-based domain adaptation for speech emotion recognition[J]. IEEE Signal Processing Letters, 2017, 24(4): 500-504.
- [8] LI Wen, DUAN Lixin, XU Dong, et al. Learning with augmented features for supervised and semi-supervised heterogeneous domain adaptation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(6): 1134-1148.
- [9] 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 Chao, SHEN Fei, YAN Ruqiang. 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.
- [10] LU Weining, LIANG Bin, CHEN Yu, et al. Deep model based domain adaptation for fault diagnosis[J]. IEEE Transactions on Industrial Electronics, 2017, 64(3): 2296-2305.
- [11] PAN S J, YANG Qiang. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [12] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition in Las Vegas, Nevada, June 26 - July 1, 2016. USA: IEEE, 2016: 770-778.
- [13] GRETTON A, BORGWARDT M K, RASCH M, et al. A kernel method for the two-sample-problem[C]// The Nineteenth Annual Conference on Neural Information Processing Systems in Vancouver, British Columbia, Canada, December 4-7, 2006. USA: IEEE, 2006: 513-520.
- [14] YOSINSKI J, CLUNE J, BENGIO Y, et al. How transferable are features in deep neural networks[C]// The Twenty-seventh Annual Conference on Neural Information Processing Systems in Kuching, Malaysia, November 3-6, 2014. Germany: Springer, 2014: 3320-3328.
- [15] LONG Mingsheng, WANG Jianmin, CAO Yue, et al. Deep learning of transferable representation for scalable domain adaptation[J]. IEEE Transactions on Knowledge and Data Engineering, 2016, 28(8): 2027-2040.
- [16] LEE D H. Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks[C]// The Thirtieth International Conference on Machine Learning Workshop on Challenges in Representation Learning in Atlanta, Georgia, USA, June 16-21, 2013.
- [17] PAN S J, TSANG W I, KWOK T J, et al. Domain adaptation via transfer component analysis[J]. IEEE Transactions on Neural Networks, 2011, 22(2): 199-210.
-
- 作者简介: 雷亚国(通信作者), 男, 1979 年出生, 博士, 教授, 博士研究生导师。主要研究方向为大数据智能故障诊断与寿命预测、机械状态健康监测与智能维护、机械系统建模与动态信号处理。
E-mail: yaguolei@mail.xjtu.edu.cn