DOI: 10.3901/JME.2020.09.084

基于提升深度迁移自动编码器的轴承智能故障诊断*

邵海东¹ 张笑阳² 程军圣¹ 杨宇¹

(1. 湖南大学汽车车身先进设计制造国家重点实验室 长沙 410082;
2. 中国航空工业集团公司西安航空计算技术研究所 西安 710065)

摘要: 实际工程中, 含标注信息的轴承监测数据严重缺乏, 这将导致其智能故障诊断模型难以有效构建。提出了一种基于提升深度迁移自动编码器的新方法用于不同机械设备间的轴承故障智能诊断。首先, 采用可缩放指数型线性单元作为标准自动编码器的激活函数, 提升原始振动数据的映射质量。然后, 非负约束用于修正代价函数, 进一步减少重构误差。其次, 构建提升深度自动编码器并用充足可用的源域数据进行预训练, 得到的参数作为目标模型的初始化参数。最后, 目标域中仅有的一个训练样本用于目标模型的微调以适应剩余的测试样本。将所提方法用于分析不同轴承的试验振动数据, 结果表明, 所提方法能基于原始振动数据有效实现不同种机械设备间的迁移诊断。

关键词: 提升深度自动编码器; 轴承故障; 迁移诊断; 可缩放指数型线性单元; 非负约束

中图分类号: TH17

Intelligent Fault Diagnosis of Bearing Using Enhanced Deep Transfer Auto-encoder

SHAO Haidong¹ ZHANG Xiaoyang² CHENG Junsheng¹ YANG Yu¹

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082;
2. Xi'an Aeronautics Computing Technique Research Institute, AVIC, Xi'an 710065)

Abstract: The collected data with labeled information of bearing is far insufficient in engineering practice, which is a great challenge for effectively training an intelligent diagnosis model. A new method called enhanced deep transfer auto-encoder is proposed for bearing fault diagnosis of different machines. First, scaled exponential linear unit is used to improve the quality of the mapped vibration data collected from bearing. Second, nonnegative constraint is adopted to modify the cost function to reduce reconstruction error. Third, an enhanced deep auto-encoder model is pre-trained with sufficient available data in the source domain and its parameters are transferred to initialize the target domain model. Finally, the enhanced deep transfer model is fine-tuned with only one training sample in the target domain to adapt to the characteristics of the remaining testing samples. Two sets of vibration data from bearings installed in the different machines are used to verify the feasibility of the proposed method. The analysis result confirms that the proposed method is able to achieve effective transfer diagnosis between different machines.

Key words: enhanced deep auto-encoder; bearing fault; transfer diagnosis; scaled exponential linear unit; nonnegative constraint

0 前言

机械设备广泛用于现代社会的各行各业中, 轴承是机械设备中最为通用的组成部件, 一旦发生故障, 很可能引发严重的事故。随着传感器和工业互联网等技术的快速发展, 轴承运行过程中的海量监

测数据被逐渐采集积累, 如何有效挖掘其中蕴含的代表性故障信息已成为当下轴承健康监测领域的研究热点^[1]。

智能故障诊断技术能显著提升机械设备的自动化推理能力。在过去很长一段时间内, 浅层学习模型, 如支持向量机(Support vector machine, SVM)和人工神经网络(Artificial neural network, ANN)等, 在机械故障智能诊断研究中占据了绝对主流地位^[2]。然而, 基于浅层学习模型的智能诊断体系严重依赖信号预处理技术与人工特征工程^[3-5]。近年来,

* 国家自然科学基金(51905160, 51875183)和中央高校基本科研业务费专项资金(531118010335)资助项目。20190529收到初稿, 20200108收到修改稿

随着计算机硬件性能的提升和无监督预训练算法的兴起,深度学习模型被开发并成功用于机械故障的智能诊断中^[6-7]。由于能够直接从原始数据或低层次特征数据中挖掘代表性信息,以及强大的多模式分类能力,基于深度学习的智能诊断引起了越来越多的国内外学者的关注。然而,为了获得尽可能高的故障识别率,无论是基于浅层结构还是深度结构的智能诊断模型,其成功训练都离不开充足可用的监测数据,即健康状态的标注信息充足^[8]。更苛刻的是,模型的训练样本和测试样本须满足同分布要求。

将上述的智能诊断策略用于实际工程中的轴承诊断任务时会面临以下几个挑战:① 轴承长期运行过程中积累了海量的监测数据,如果仅仅标记其中极其有限的监测数据所对应的健康状态信息,其代价往往是可接受的;但是如果要对绝大多数或者全部监测数据进行标记,代价非常巨大,甚至是不可能实现的;② 实际工程中轴承的工况复杂多变,采集的振动信号不平稳且包含噪声,以及故障发生与表征动态变化等客观原因,训练样本和测试样本往往难以实现理想的同分布要求;③ 轴承安装于不同的机械设备,由于实验设备和工程设备工况不一、型号不一、结构不一、材料不一、采样不一等,如果直接将基于实验设备监测数据训练所得的智能诊断模型用于工程设备的测试分析,其效果难以令人满意。庆幸的是,实验设备中较易获取典型故障信息丰富、状态标记信息充足的轴承监测数据,如能将实验设备中积累的诊断经验知识应用于工程设备,是很有现实意义的。

迁移学习是近年来人工智能领域的一个重大突破,旨在运用已有的知识解决相关但不完全相同领域中的问题^[9]。迁移学习能在很大程度上放松训练样本(源域数据)必须充足可用,且须和测试样本(目标域数据)满足同分布的强制要求,目前已成功用于图像识别、语音识别、文本识别等传统的模式识别领域。最近 3 年,迁移学习也开始逐渐引起了机械智能诊断领域研究学者的关注^[10-12]。然而当前的研究多数仅考虑安装于同一机械设备的轴承在不同运行工况下(变转速或变负载)的迁移诊断任务,并未涉及不同设备间的迁移诊断。雷亚国等考虑了实验室轴承和电力机车轴承间的迁移诊断策略,然而该研究局限于不同故障类型的区分^[8]。综上,针对不同机械设备间的轴承迁移诊断任务,研究新型的迁移学习策略实现不同故障类型的区分以及同类故障不同损伤程度的区分,有助于加快智能诊断技术的工程化步伐。

提出了一种基于提升深度迁移自动编码器的新方法用于不同机械设备间的轴承故障智能诊断。可缩放指数型线性单元和非负约束用于增强自动编码器性能,采用充足可用的源域数据预训练提升的深度自动编码器模型并得到相应的模型参数,将参数迁移至目标域模型并用少量的目标域训练数据加以微调。所提方法的有效性在不同机械设备的轴承振动数据中得到验证。

1 深度模型迁移思想

当前迁移学习策略主要分为 4 类:基于样本的迁移、基于特征的迁移、基于模型的迁移和基于关系的迁移。与其他迁移方式相比,基于模型的迁移简单易行,非常适用于仅有少量训练样本情形下分类问题的解决^[13]。此外,深度学习模型中微调算法的成功应用,更是大大的提升了基于模型的迁移策略研究的空间。

深度模型迁移旨在将迁移学习思想嵌入深度学习模型的训练机制中,其核心是将源域 $\mathbf{D}^S = \{\mathbf{x}_i^S, \mathbf{y}_i^S\}_{i=1}^{n_S}$ 中充足可用的数据样本用于深度模型的无监督预训练,保持得到模型参数不变作为目标域模型的初始化参数,然后将目标域 $\mathbf{D}^T = \{\mathbf{x}_i^T, \mathbf{y}_i^T\}_{i=1}^{n_T}$ 中的少量训练样本微调模型,进一步优化参数以适应目标域中剩余的新数据,以期解决源域数据样本与目标域数据样本分布不同的问题。其中, $\mathbf{x}_i^S$ 为源域中第 i 个训练数据样本,其对应标签信息为 $\mathbf{y}_i^S$, n_S 是源域所含样本的个数; $\mathbf{x}_i^T$ 为目标域中第 i 个训练数据样本,其对应标签信息为 $\mathbf{y}_i^T$, n_T 是源域所含样本的个数, $n_T \ll n_S$ 。

2 所提方法

提出了一种基于提升深度迁移自动编码器的新方法用于不同机械设备间的轴承故障智能诊断。深度自动编码器模型的提升之处在于:基于可缩放指数型线性单元设计激活函数,基于非负约束修正代价函数。

2.1 基于可缩放指数型线性单元的激活函数

自动编码器(Auto-encoder, AE)是一种深受欢迎的深度学习基模型。如图 1 所示,AE 分为编码网络和解码网络两个部分,编码网络将高维的输入数据转换为低维的特征表示,解码网络将特征表示转化为输入数据的重构形式。AE 的目的是通过尽可能地实现输入数据的重构以获得代表性的特征表示,其基本公式为

图1 自动编码器基本结构

$$\mathbf{h} = \mathbf{g}(\mathbf{x}) = \mathbf{s}_g(\mathbf{w}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}) \quad (1)$$

$$\mathbf{z} = \mathbf{f}(\mathbf{h}) = \mathbf{s}_f(\mathbf{w}^{(2)}\mathbf{h} + \mathbf{b}^{(2)}) \quad (2)$$

$$C^{\text{Tra}} = \frac{1}{2} \sum_{i=1}^N (z_i - x_i)^2 + r \sum_{j=1}^M \text{KL}(\mu \| \hat{\mu}_j) \quad (3)$$

$$\text{KL}(\mu \| \hat{\mu}_j) = \mu \lg \frac{\mu}{\hat{\mu}_j} + (1 - \mu) \lg \frac{1 - \mu}{1 - \hat{\mu}_j} \quad (4)$$

式中, $\mathbf{x} \in \mathbb{R}^N$ 代表一个输入数据样本; $\mathbf{h} \in \mathbb{R}^M$ 代表隐层特征数据; $\mathbf{z} \in \mathbb{R}^N$ 代表输入 $\mathbf{x}$ 的重构表示; $\mathbf{s}_g$ 为编码网络的激活函数通常选为 Sigmoid; $\mathbf{s}_f$ 为解码网络的激活函数, 主要根据原始输入数据的归一化范围选择函数形式, 以尽可能实现高精度的重构; $\mathbf{w}^{(1)}, \mathbf{b}^{(1)}, \mathbf{w}^{(2)}, \mathbf{b}^{(2)}$ 为 AE 的模型参数, 包含各层的权值和偏置; C^{Tra} 为通用的代价函数; r 为系数惩罚项因子; μ 为稀疏系数。

标准 AE 模型的隐层激活函数 Sigmoid, 其输出不是以 0 为中心的, 且存在梯度消失, 往往致使权重更新效率降低^[14]。ReLU 是另一种应用较为广泛的激活函数, 克服 Sigmoid 的部分不足之处, 然而在训练过程中存在输出不是以 0 为中心以及神经元“坏死”等问题^[15]。2017 年, 一种名为可缩放指数型线性单元(Scaled exponential linear unit, SELU)的新型激活函数被开发用于深度学习模型的性能提升, 该激活函数有效融合了 Sigmoid 和 ReLU 的有利特点, 克服了梯度消失和梯度爆炸的问题。此外, 输入样本经过 SELU 的映射能高度满足零均值和单位方差的归一化分布属性^[16]。SELU 函数波形如图2, 公式定义如下

$$\text{SELU}(x) = \lambda \begin{cases} x & x > 0 \\ \alpha e^x - \alpha & x \leq 0 \end{cases} \quad (5)$$

式中, λ 和 α 是两个可调整的参数。替换新型激活函数后隐层的输出以及重构输出分别为

$$h_j = \lambda \begin{cases} \sum_{i=1}^N w_{ji}^{(1)} x_i + b_j^{(1)} & x_i > 0 \\ \alpha \cdot \exp\left(\sum_{i=1}^N w_{ji}^{(1)} x_i + b_j^{(1)}\right) - \alpha & x_i \leq 0 \end{cases} \quad (6)$$

图2 SELU 激活函数波形

$$z_i = \lambda \cdot s_f \left(\sum_{j=1}^M w_{ji}^{(2)} \left(\sum_{i=1}^N w_{ji}^{(1)} x_i + b_j^{(1)} \right) + b_i^{(2)} \right) \quad (7)$$

$$z_i = \lambda \cdot s_f \left(\sum_{j=1}^M w_{ji}^{(2)} \left(\alpha \cdot \exp\left(\sum_{i=1}^N w_{ji}^{(1)} x_i + b_j^{(1)}\right) - \alpha \right) + b_i^{(2)} \right) \quad (8)$$

式中, $w_{ji}^{(L)}$ 为第 L 层节点 i 与第 $L+1$ 层节点 j 间的连接权值($L=1,2$); $b_j^{(1)}$ 和 $b_i^{(2)}$ 分别表示隐层节点 j 和输出层节点 i 的偏置。式(6)是隐层节点 j 的输出, 由于后续分析中将原始输入的振动数据归一化在 $[-1,1]$ 区间, 为了实现高质量的重构, 解码网络的激活函数 s_f 选为双曲正切函数 Tanh, 式(7)和式(8)分别是 $x_i > 0$ 和 $x_i \leq 0$ 时输出层节点 i 的输出。

2.2 基于非负约束的修正代价函数

在传统的 AE 中, 为了避免过拟合, 通常还需要在代价函数中引入权重衰减项, 则此时代价函数为

$$C^{\text{Tra}} = \frac{1}{2} \sum_{i=1}^N (z_i - x_i)^2 + r \sum_{j=1}^M \text{KL}(\mu \| \hat{\mu}_j) + \frac{\sigma}{2} \sum_{L=1}^2 \sum_{i=1}^{s_L} \sum_{j=1}^{s_{L+1}} (w_{ji}^{(L)})^2 \quad (9)$$

式中, σ 为权重衰减项; s_L 为第 L 层神经元的个数。

研究表明, 设定 AE 模型的权重系数非负以减少每一层中负权值的数量, 将有助于减少 AE 模型重构误差^[17]。引入非负约束的修正的代价函数为

$$C^{\text{Mod}} = \frac{1}{2} \sum_{i=1}^N (z_i - x_i)^2 + r \sum_{j=1}^M \text{KL}(\mu \| \hat{\mu}_j) + \frac{\sigma}{2} \sum_{L=1}^2 \sum_{i=1}^{s_L} \sum_{j=1}^{s_{L+1}} G(w_{ji}^{(L)}) \quad (10)$$

$$G(w_{ji}^{(L)}) = \begin{cases} (w_{ji}^{(L)})^2 & w_{ji}^{(L)} < 0 \\ 0 & w_{ji}^{(L)} \geq 0 \end{cases} \quad (11)$$

式中, C^{Mod} 为修正的代价函数。与传统的 AE 模型训练目的一致, 采用随机梯度下降算法调整权值 $w_{ji}^{(L)}$ 和偏置 $b_j^{(1)}, b_i^{(2)}$, 使得修正的代价函数最小化。

$$w_{ji}^{(L)} = w_{ji}^{(L)} - \eta \frac{\partial}{\partial w_{ji}^{(L)}} C^{\text{Mod}} =$$

$$w_{ji}^{(L)} - \eta \left(\frac{\partial}{\partial w_{ji}^{(L)}} C^{\text{Tra}} + \sigma g(w_{ji}^{(L)}) \right) \quad (12)$$

$$g(w_{ji}^{(L)}) = \begin{cases} w_{ji}^{(L)} & w_{ji}^{(L)} < 0 \\ 0 & w_{ji}^{(L)} \geq 0 \end{cases} \quad (13)$$

$$b_j^{(1)} = b_j^{(1)} - \eta \frac{\partial}{\partial b_j^{(1)}} C^{\text{Tra}} \quad j = 1, 2, \dots, M$$

$$b_i^{(2)} = b_i^{(2)} - \eta \frac{\partial}{\partial b_i^{(2)}} C^{\text{Tra}} \quad i = 1, 2, \dots, N \quad (14)$$

为了使进一步提升学习特征的质量同时具备分类能力, 需要增加提升 AE 的深度, 并且在最高层添加 softmax 分类器, 由此构建提升深度自动编码器模型。具体地, 原始数据作为第一个 AE 的输入, 经无监督预训练后, 每一个 AE 的隐层输出特征作为下一个的输入数据, 最后一个 AE 的隐层输出作为深度特征输入 softmax, 借助有监督微调实现高精度的分类任务。

2.3 所提方法主要步骤

提出了一种基于提升深度迁移自动编码器的新方法用于不同机械设备间的轴承故障智能诊断, 主要步骤如下。

步骤 1: 从一台机械设备中采集充足可用的轴承振动数据作为源域数据, 将其划分为训练样本和测试样本。

步骤 2: 基于 SELU 激活函数和修正代价函数设计提升的自动编码器模型。

步骤 3: 用源域中的训练样本训练提升的深度自动编码器模型(含 softmax 分类器), 并用源域中的测试样本加以检验, 获取诊断性能优异的源域深度模型。

步骤 4: 采集另一台机械设备的轴承振动数据作为目标域数据, 将其划分为训练样本和测试样本, 其中训练样本量极其少量。

步骤 5: 将已训练完的源域深度模型的参数, 包括结构层数, 每层节点数、权重参数以及偏置参数等迁移至目标模型, 作为目标模型的初始化参数。

步骤 6: 用目标域中的少量训练样本微调目标模型, 使式(10)中的损失函数最小。

步骤 7: 利用目标域中剩余的测试样本验证深度迁移模型的诊断性能。

3 仿真案例验证

3.1 仿真数据描述

通过构造调制源为两个载波中心的仿真信号,

来模拟滚动轴承发生内圈和外圈故障时的冲击响应信号

$$x_o(t) =$$

$$\sum_{i=1}^{N_o} \left[\exp \left(-\zeta_o 2\pi f_{o1} \left(t - \frac{i}{f_o} \right) \right) \sin 2\pi f_{o1} \left(t - \frac{i}{f_o} \right) \sqrt{1 - \zeta_o^2} + \right.$$

$$\left. \exp \left(-\zeta_o 2\pi f_{o2} \left(t - \frac{i}{f_o} \right) \right) \sin 2\pi f_{o2} \left(t - \frac{i}{f_o} \right) \sqrt{1 - \zeta_o^2} \right] + w \quad (15)$$

$$x_i(t) =$$

$$\sum_{i=1}^{N_i} \left[\exp \left(-\zeta_i 2\pi f_{i1} \left(t - \frac{i}{f_i} \right) \right) \sin 2\pi f_{i1} \left(t - \frac{i}{f_i} \right) \sqrt{1 - \zeta_i^2} + \right.$$

$$\left. \exp \left(-\zeta_i 2\pi f_{i2} \left(t - \frac{i}{f_i} \right) \right) \sin 2\pi f_{i2} \left(t - \frac{i}{f_i} \right) \sqrt{1 - \zeta_i^2} \right] + w \quad (16)$$

式中, $x_o(t)$ 的载波中心频率分别为 $f_{o1} = 2\,000\text{ Hz}$ 和 $f_{o2} = 5\,200\text{ Hz}$; 阻尼比 $\zeta_o = 0.02$; 外圈故障特征频率 $f_o = 64.82\text{ Hz}$; $x_i(t)$ 的载波中心频率分别为 $f_{i1} = 1\,200\text{ Hz}$ 和 $f_{i2} = 5\,200\text{ Hz}$; 阻尼比 $\zeta_i = 0.02$; 内圈故障特征频率 $f_i = 87.90\text{ Hz}$ 。用 $12\,800\text{ Hz}$ 的采样频率对 $x_o(t)$ 和 $x_i(t)$ 进行离散化采样, 无噪声数据作为源域, 添加随机噪声 $w = 0.4 \times \text{randn}(1, n)$ 后的数据作为目标域, 如图 3 所示, 其中(1)为内圈故障信号, (2)为外圈故障信号。由图可知, 源域和目标域由于噪声的不同存在一定分布差异。

图 3 轴承内圈和外圈故障仿真信号

3.2 仿真信号迁移诊断结果分析

将所提方法(DAE: SELU & C^{Mod})与目前常用的诊断方法比较, 包括标准深度自动编码器(DAE: Sigmoid & C^{Tra}), BP 神经网络(Back propagation neural network, BPNN), 支持向量机(SVM), 极限学习机(Extreme learning machine, ELM)和随机森林(Random forest, RF)。源域中每类训练样本为 80 个, 目标域中用于微调的每类样本为 1 个, 用于测试的每类样本为 30 个。前 2 种方法的输入为 200 维的原始振动数据, 采用模型迁移思想, 后 4 种方法的输入为 10 个常用时域特征值^[18], 不涉及模型迁移策略。

为了避免偶尔性,所有方法都执行了10次重复试验,具体结果如表1所示。所提方法的平均诊断准确率为98.50% (594/600, $600=30 \times 10 \times 2$),略高于标准深度自动编码器的94.83%,远高于其它4种传统的浅层智能诊断模型准确率,分别为63.67%,67.00%,66.33%和67.67%。尽管为仿真数据,然而由于噪声的影响致使源域样本和目标域样本存在一定的分布差异,此时直接将基于源域数据训练所得的智能诊断模型用于目标域的测试分析,其效果往往不佳。

表1 仿真信号迁移诊断结果对比

诊断模型	输入数据	平均准确率(%)
DAE (SELU & C^{Mod})	原始数据	98.50(591/600)
DAE (Sigmoid & C^{Tra})	原始数据	94.83(569/600)
BPNN	时域特征	63.67(382/600)
SVM	时域特征	67.00(402/600)
ELM	时域特征	66.33(398/600)
RF	时域特征	67.67(406/600)

4 试验案例验证

4.1 源域数据和目标域数据描述

源域轴承数据:模拟试验设备中获取的充足可用的数据。源自美国凯斯西楚大学轴承实验台,如图4a所示。选取了1 797 r/min转速下驱动端6类轴承运行状态的振动数据,包含不同故障类型和损伤程度,每类包含样本300个,其中训练样本200个,测试样本100个,每个样本是一段包含400个连续采样点的信号段。采样频率为12 kHz,负载为0 hp。

目标域轴承数据:模拟工程设备中获取的严重不足的数据。源自自制的轴承故障实验台,如图4b所示。在900 r/min转速下采集轴承振动数据,每类的样本100个,然而其中训练样本只有1个,余下99个为测试样本。采样频率为10 kHz,负载为2 kN。

图4 不同机械设备的轴承测试台

源域和目标域轴承数据集的更多比较与描述如表2所列,6类轴承运行状态的数据样本如图5所示,由图可知,源域数据和目标域数据存在一定分布差异。(图5由上至下依次对应表2中的6类轴承状态)

图5 不同运行状态的轴承振动信号

表2 源域和目标域数据描述

轴承数据集	转速/(r/min)	轴承运行状态	样本总数	训练样本总数
源域数据	1 797	正常	1 800 (300×6)	1 200 (200×6)
		滚动体故障 0.18 mm		
		内圈故障 0.18 mm		
		内圈故障 0.53 mm		
		外圈故障 0.18 mm		
		外圈故障 0.53 mm		
目标域数据	900	正常	600 (100×6)	6 (1×6)
		滚动体故障 0.2 mm		
		内圈故障 0.2 mm		
		内圈故障 0.4 mm		
		外圈故障 0.2 mm		
		外圈故障 0.3 mm		

4.2 迁移诊断结果分析

首先验证迁移策略的必要性,将所提方法(方法1)与标准自动编码器(方法2),标准深度置信网络(方法3)和标准卷积神经网络(方法4)进行对比。需要说明的是:4种方法的输入为400维度的原始振动数据,后3种方法是不涉及模型迁移策略的智能诊断模式,即训练数据均为源域数据集中的200个训练样本,目标域中的99个测试样本作为测试数据。所提方法利用目标域中的1个训练样本来微调基于源域数据集中的200个训练样本训练所得的深度模型,然后用目标域中余下的99个测试样本检验。

为了避免偶尔性,总共执行了8次重复试验,诊断结果如图6所示。所提方法的平均诊断准确率为89.48% (4 252/4 672),标准差为0.630。尽管目标域训练样本只有1个,但是所提方法仍能在一定程度上实现不同机械设备间的迁移诊断,与之相比,其它3种方法的平均准确率均低于50%。主要原因为源域的训练样本和目标域的测试样本存在明显的分布差异。所提方法借助于目标域中的1个训练样本微调基于源域数据训练所得的性能优异的深度模型,进一步优化参数以适应目标域中剩

余的新数据, 成功将源域学习得到的知识迁移用于目标域任务。

图6 重复试验中各方法诊断结果

其次将所提方法与经典迁移学习方法进行对比, 对比方法有 TrAdaBoost, 迁移成分分析(Transfer component analysis, TCA)以及联合分布适配(Joint distribution adaptation, JDA)^[19]。所有方法的输入均为 400 维度的原始振动数据, 训练数据均为源域数据集集中的 200 个训练样本, 目标域中的 99 个测试样本作为测试数据。重复试验的具体结果如表 3 所示。由表可知, 所提方法的平均诊断准确率明显高于其他 3 种经典迁移学习方法的 71.68%, 75.19%和 72.02%。这三种学习方法虽具有一定的迁移能力, 但并不具备足够的特征学习能力, 无法从原始数据中挖掘代表性特征信息。

表3 不同迁移学习方法对比

诊断模型	输入数据	平均准确率(%)
所提方法	原始数据	89.48(4 252/4 672)
TCA	原始数据	71.68(3 349/4 672)
JDA	原始数据	75.19(3 513/4 672)
TrAdaBoost	原始数据	72.02(3 365/4 672)

最后验证所提提升深度自动编码器的优越性, 将其与另外 5 种深度自动编码器模型进行对比。这里, 深度自动编码器模型的不同源于激活函数和代价函数形式, 所有模型输入为 400 维度的原始振动数据, 含 3 个隐层, 具体结构为“400-200-100-50-6”。SELU 激活函数的两个参数 λ 和 α 分别设置为 1.05 和 1.673。在迁移诊断过程中, 各模型均先利用目标域中的 1 个样本来微调基于源域数据训练所得的深度模型, 再分析目标域中余下的 99 个测试样本。

重复试验的具体结果如表 4 和图 7 所示。所提迁移模(模型 1: SELU & C^{Mod})的平均诊断准确率为 89.48%, 高于其他 5 种迁移模型的平均准确率, 依次为 85.14%, 81.99%, 83.42%, 83.29%和 84.30%。所提迁移模型的标准差为 0.630, 低于对比模型, 展现了良好的稳定性。主要原因为可缩放指数型线性单元可提升原始振动数据的归一化属性, 非负约束修正的代价函数可进一步提升重构质量。通过对比

模型 1 和 2, 模型 3 和 5, 模型 4 和 6 体现修正代价函数的优势。通过对比模型 1, 5 和 6 体现 SELU 激活函数的优势, 进一步分析模型 1 与 5 输出的深层特征数据, 通过 t-分布领域嵌入算法进行降维可视化, 如图 8 所示。由此可知, 所提模型学习得到的深度特征更具代表性, 更易区分。

表4 不同深度迁移自动编码器模型诊断结果对比

深度迁移模型	平均准确率(%)	标准差
模型 1 (SELU & C^{Mod})	89.48(4 252/4 672)	0.630
模型 2 (SELU & C^{Tra})	85.14(4 046/4 672)	0.730
模型 3 (Sigmoid & C^{Tra})	81.99(3 896/4 672)	0.685
模型 4 (ReLU & C^{Tra})	83.42(3 964/4 672)	0.779
模型 5 (Sigmoid & C^{Mod})	83.29(3 958/4 672)	0.684
模型 6 (ReLU & C^{Mod})	84.30(4 006/4 672)	0.735

图7 重复试验中各迁移模型诊断结果

图8 深度特征二维可视化

5 结论

提出了一种基于提升深度迁移自动编码器的新方法, 旨在解决不同机械设备间的轴承故障智能诊断任务, 主要得到以下结论。

(1) 基于可缩放指数型线性单元设计的激活函数, 以及基非负约束修正的代价函数, 可提升自动编码器的性能, 学习更具代表性的诊断信息。

(2) 两组源自不同试验设备的轴承振动数据模拟实验设备和工程设备的数据特点, 验证了在仅有一个训练样本情况下, 所提方法能借助相关辅助数据中积累的知识有效实现轴承的迁移诊断任务。

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 Yagu, 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] SHAO Haidong, JIANG Hongkai, ZHANG Haizhou, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network[J]. IEEE Transactions on Industrial Electronics, 2018, 65(3): 2727-2736.
- [3] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报, 2015, 51(21): 49-56.
- LEI Yaguo, JIA Feng, ZHOU Xin, et al. A deep learning-based method for machinery health monitoring with big data[J]. Journal of Mechanical Engineering, 2015, 51(21): 49-56.
- [4] SHAO Haidong, JIANG Hongkai, ZHAO Huiwei, et al. A novel deep autoencoder feature learning method for rotating machinery fault diagnosis[J]. Mechanical Systems and Signal Processing, 2017, 95: 187-204.
- [5] SHAO Haidong, JIANG Hongkai, ZHAO Huiwei, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis[J]. Knowledge-Based Systems, 2017, 119: 200-220.
- [6] ZHAO Rui, YAN Ruqiang, CHEN Zhenghua, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [7] 姜洪开, 邵海东, 李兴球. 基于深度学习的飞行器智能故障诊断方法[J]. 机械工程学报, 2019, 55(7): 27-34.
- JIANG Hongkai, SHAO Haidong, LI Xingqiu. Deep learning theory with application in intelligent fault diagnosis of aircraft[J]. Journal of Mechanical Engineering, 2019, 55(7): 27-34.
- [8] 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, 5(7): 1-8.
- LEI Yaigu, 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.
- [9] PAN S J, YANG Qiang. A Survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 陈雪峰, 瞿艳阳. 智能运维与健康管理[M]. 北京: 机械工业出版社, 2018.
- CHEN Xuefeng, ZI Yanyang. Intelligent maintenance and health management [J]. Beijing: China Machine Press, 2018.
- [14] VINOD N, HINTON G E. Rectified linear units improve restricted Boltzmann machines[C]//International Conference on Machine Learning in Haifa, Israel, June 21- June 24, 2010: 807-814.
- [15] LU Lu, SHIN Y, SU Yanhui, et al. Dying ReLU and initialization: Theory and numerical examples[EB/OL]. [2019-03-15]. Cornell University Library 2019, <http://export.arxiv.org/abs/1903.06733>.
- [16] KLAMBAUER G, UNTERTHINER T, MAYR A, et al. Self-normalizing neural networks[EB/OL]. [2017-09-07]. Cornell University Library 2017, <https://arxiv.org/abs/1706.02515v4>.
- [17] HOSSEINI-ASL E, ZURADA J M, NASRAOUI O. Deep learning of part-based representation of data using sparse autoencoders with nonnegativity constraints[EB/OL]. [2016-01-12]. Cornell University Library 2016, <https://arxiv.org/abs/1601.02733>.
- [18] LEI Yaguo, HE Zhengjia, ZI Yanyang. EEMD method and WNN for fault diagnosis of locomotive roller bearings[J]. Expert Systems with Applications, 2011, 38(6): 7334-7341.
- [19] QIAN Weiwei, LI Shunming, YI Pengxing, et al. A novel transfer learning method for robust fault diagnosis of rotating machines under variable working conditions[J]. Measurement, 2019, 138: 514-525.

作者简介: 邵海东(通信作者), 男, 1990 年出生, 博士, 讲师。主要研究方向为故障诊断与智能预测。

E-mail: hdsiao@hnu.edu.cn

张笑阳, 男, 1990 年出生, 硕士, 助理工程师。主要研究方向为设备测试性与安全性分析。

E-mail: zxyang123456@126.com