

DOI: 10.19650/j.cnki.cjsi.J2108717

有限变工况特征迁移学习方法及其在高速列车轴箱轴承故障诊断中的应用*

罗宏林¹, 柏 林¹, 侯东明², 彭 畅³

(1. 重庆大学机械传动国家重点实验室 重庆 400044; 2. 北京交通大学机械与电子控制工程学院 北京 100044;
3. 中车青岛四方机车车辆股份有限公司技术中心 青岛 266111)

摘 要:以高速列车轴箱轴承为研究对象,提出了一种适用于有限数量变工况下的轴承故障诊断方法。该方法以有监督的学习模式构造自编码器,将不同工况下特征值集向参考工况下特征集做映射迁移,从而减弱由工况变化引起的轴承故障特征值改变的影响。再将迁移后的特征集输入由参考工况特征集预训练的基于卷积神经网络的故障诊断模型,实现变工况下轴承故障的诊断。凯斯西储大学轴承公开数据集和高速列车轴箱轴承数据集的试验结果表明,经监督式自编码器特征迁移后的轴承故障识别准确率有了较大提升,该方法能够较好的实现有限工况下的特征序列的迁移,解决工况变化带来的故障特征的畸变问题。

关键词: 轴箱轴承; 监督式自编码器; 变工况特征迁移; 卷积神经网络; 故障诊断

中图分类号: TH17 TP206 文献标识码: A 国家标准学科分类代码: 510.40

A transfer learning method for bearing fault diagnosis under finite variable working conditions and its application in train axle-box bearings fault diagnosis

Luo Honglin¹, Bo Lin¹, Hou Dongming², Peng Chang³

(1. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China;
2. School of Mechanical, Electronic and Control Engineering, Beijing Jiaotong University, Beijing 100044, China;
3. Technology Center, CRRC Qingdao Sifang Co., Ltd., Qingdao 266111, China)

Abstract: This article takes the high-speed train axle box bearing as the research object. A bearing fault diagnosis method is proposed to deal with finite variable working conditions, which is based on the supervised auto encoder feature representation transfer. The feature sequences of different working conditions are mapped to the reference condition feature sequences. In this way, the influence of condition change on bearing fault feature is decreased. The migrated features are inputted into the fault diagnosis model based on the convolution neural network, which is pre-trained by the reference condition training feature sets. Then, the axle box bearing fault diagnosis is achieved under variable working conditions. The open bearing data of Case Western Reserve University and the high-speed axle box bearing data are utilized. Experimental results show that the accuracy of fault identification has been greatly improved after feature migration. The method can achieve the feature migration under different working conditions and reduce the distortion of fault features caused by the change of working conditions.

Keywords: axle box bearing; supervised auto-encoder; feature representation transfer; convolutional neural network; fault diagnosis.

0 引 言

准确的轴承健康状态检测是旋转机械视情维修 (condition based maintenance, CBM) 能够有效实施维护

决策的关键。目前设备状态监测的方法可以分为以下 3 种^[1-2]: 基于先验知识、基于传统机器学习 (machine learning, ML) 和基于深度学习 (deep learning, DL)。在基于深度学习的设备状态监测方法中, 基于卷积神经网络 (convolutional neural network, CNN) 的智能故障诊断方

收稿日期: 2021-10-15 Received Date: 2021-10-15

* 基金项目: 国家自然科学基金 (52175077) 项目资助

法能够学习样本数据的内在规律和表示层次,在轴承故障诊断方面取得了一定的成果^[3]。目前基于 CNN 的轴承故障诊断方法从模型输入角度可以分为以下 3 种方式:1)直接将原始信号作为 CNN 的输入实现端对端轴承故障诊断^[4-5]。2)提取信号的频谱或者时频图作为 CNN 的输入实现轴承故障诊断^[6-7]。3)提取用于传统机器学习的信号特征集作为 CNN 输入实现轴承故障诊断^[8-9]。

对于单一工况下的轴承故障诊断,现有基于深度学习的方法已经可以取得较高的故障识别率。但在实际工程应用中,由单一工况数据集预训练的轴承故障诊断模型对于负载或转速的变化后采集的轴承测试样本泛化能力不足,故障识别率较低。变工况对基于深度学习的轴承故障诊断提出了两个挑战^[10]:1)数据依赖。基于深度学习的轴承故障检测方法对训练数据具有依赖性。训练好的模型对于与训练数据集具有近似特征分布的数据能有较好的效果,而一旦这些特征分布偏移,故障识别率将会很差。2)训练数据不足。基于深度学习的轴承故障检测方法需要大量具有轴承健康状态标签的数据来理解轴承失效的潜在模式。而轴承数据采集系统的搭建通常是复杂且昂贵的,要构建出大型、高质量、带健康状况标签的轴承训练和测试数据集十分困难。

目前变工况下旋转机械故障诊断的方法中,主流方法是将时域信号转换为角域信号的阶比分析方法,该方法需要采集或者人工近似生成鉴相信号限制了其应用场景^[2,11-12]。在基于机器学习的旋转机械变工况故障诊断方法中,基于迁移学习的轴承多工况故障诊断能减小不同工况下的数据分布差异,实现轴承故障诊断知识的跨域迁移。迁移学习通过放松训练数据和测试数据必须是独立且同分布的假设,将知识从源域迁移到目标域。迁移学习被归纳为 4 类^[13]:实例迁移、特征迁移、模型迁移以及关系迁移。其中基于特征的迁移能在源域和目标域之间构造一个共同特征表示,在轴承故障诊断方面取得了一些成果。基于特征迁移的轴承变工况故障诊断的研究主要集中在基于深度学习模型的深层特征共享^[14-15],基于几何空间或统计分布差异的模型调整^[16-18]和基于几何空间或统计分布差异的特征差异消除^[19-20]等方面。

上述变工况故障诊断方法通过提高预训练模型对变工况测试样本的泛化能力实现了轴承多工况故障诊断。但这些轴承变工况故障诊断方法是往往是复杂且耗时的,虽然学术上取得了一定的效果,但要从事学术研究到工业落地应用,现有的轴承变工况下故障识别技术还不够成熟,距离工程实践应用还有很长的路要走。要提出一种适用于某一设备且能工程实践的轴承变工况故障诊断方法需要对轴承变工况运行的含义有一个深刻的理解。轴承的工况信息包括转速、负载、润滑、温度、环境状况和人为操作等多方面能影响到轴承运行状态的相关因素及

信息。当前关于轴承变工况故障诊断的文献中,一般都将转速或者负载改变视为变工况。基于此,在实际的工业应用场景中,轴承的变工况可以归纳为有两种:连续型变工况和离散型变工况。连续型变工况下的轴承的转速或者负载连续变化,如汽车轮毂轴承;而离散型变工况下的轴承的运行速度或者负载的数量是有限的,这些有限数量的工况一般预先设定,如高速列车轴箱轴承。

对于一列正常运营的高速列车(high speed train, HST)而言,依照其行车许可^[21],除却短暂的加速与减速阶段,大部分时间都将按照运行线路运营速度或者车底最大运营速度运行,即高速列车的变工况表现为负载基本保持稳定而速度主要集中在几个固定运行速度上,例如 200、250、300 和 350 km/h 等。这使得高速列车轴箱轴承为一种典型的离散型变工况部件。由于车速只集中在几个有限运行速度上,对于轴箱轴承在不同转速下振动响应而言,可以看作是轴承在某一运行转速下的振动信号发生了线性或非线性的转变,如何求解这种转换关系是实现高速列车轴箱轴承多工况故障诊断的关键。

目前,振动检测、温度检测和声学检测是轴箱轴承的状态监控的 3 种主要途径,其中主流的分析方法是基于时域振动信号分析的方法^[22-23]。而在众多的基于振动信号分析的轴承故障诊断方法中,基于机器学习的智能诊断方法可以根据轴承振动数据评估轴箱轴承健康状况,在轴箱轴承故障诊断方面取得了一些成果。其中,主要包括基于神经网络^[24-25],基于支持向量机^[26-27]和基于卷积神经网络^[9,28]等方法。

上述关于列车轴箱轴承故障诊断方法都是在列车处于同一工况下运行而实现的,目前针对轴箱轴承变工况下故障识别技术还不够成熟,十分必要对其进行深入研究。为了实现变工况下轴箱轴承故障诊断,本文通过有监督的机器学习模式将无监督的自编码神经网络改造为一种监督式自编码神经网络(supervised auto encoder, SAE),通过将不同工况下的特征集作为输入,将参考工况下的特征集作为训练标签,进行有监督的训练学习,将不同工况下的特征集向参考工况特征集做迁移,减小由工况变化引起的故障特征值差异。在此基础上,提出了一种基于监督自编码特征迁移和卷积神经网络的高速列车轴箱轴承变工况故障诊断方法。

西储大学轴承数据集和高速列车轴箱轴承实测信号的分析结果证实了该方法对于变工况下轴承故障诊断的有效性。

1 理论背景

1.1 动机

轴承在不同稳态工况下的振动响应存在着线性或非

线性的映射关系,而这种映射关系,是可以通过一定的算法近似求解的。对于某一健康状况一定的机械设备,由于环境噪声 $s(t)$ 的影响,系统对于激励输入 $x(t)$,其卷积形式的输出 $y(t)$ 可以表示为:

$$y(t) = \sum_{k=1}^K x(t) * h_k(t) + s(t) \quad (1)$$

其中, $*$ 为卷积算子, $h_k(t)$ 为第 k 个子系统的单位冲击响应, K 为该机械系统的子系统个数。记 x_i 和 x_j 为该机械系统在工况 I 和工况 J 的激励,对应的响应为:

$$y_i(t) = \sum_{k=1}^M x_i(t) * h_k(t) + s_i(t) \quad (2)$$

$$y_j(t) = \sum_{k=1}^M x_j(t) * h_k(t) + s_j(t) \quad (3)$$

存在一个线性或者非线性的映射矩阵 ω 使得:

$$x_j = x_i \cdot \omega \quad (4)$$

则有:

$$y_j(t) = \sum_{k=1}^M (x_i(t) \cdot \omega) * h_k(t) + s_j(t) = \omega \cdot y_i(t) - \omega \cdot s_i(t) + s_j(t) \quad (5)$$

式(5)表明当叠加随机噪声时,不同工况下系统输出的变化规律与输入激励的变化规律并不一致,还应该加上环境噪声的影响,记 $\Delta(t) = s_j(t) - \omega \cdot s_i(t)$, 则有:

$$y_j(t) = \omega \cdot y_i(t) + \Delta(t) = \left(\omega + \frac{\Delta(t)}{y_i(t)} \right) \cdot y_i(t) \quad (6)$$

记 $\hat{\omega} = \omega + \frac{\Delta(t)}{y_i(t)}$, 则:

$$y_j(t) = \hat{\omega} \cdot y_i(t) \quad (7)$$

即存在一个线性或者非线性的映射矩阵 $\hat{\omega}$ 使得轴承系统在工况 I 和工况 J 的响应满足一定的映射关系。但由于噪声 $s(t)$ 是随机量,因此找不到一个单一确定的矩阵 $\hat{\omega}$ 使工况 I 和工况 J 下所有的观测样本满足式(7)的关系。只能近似求解出一个映射矩阵 $\hat{\omega}$ 使得 I 工况下的样本特征集经映射后与 J 工况下的样本特征集的映射误差尽可能小。

1.2 基于映射的轴承特征迁移学习

迁移成分分析(transfer component analysis, TCA)是特征迁移一个典型方法,适合处理域适应问题。如图1所示,对于具有不同特征值分布的源域和目标域样本,TCA 通过将源域和目标域的数据同时映射到一个优化的高维再生核希尔伯特空间,在最大化地保留源域和目标域各自的内部数据属性的同时最小化两个领域的的数据距离。

基于 TCA 的特征迁移方法能将数据从源域和目标域同时映射到新的数据空间,该思路可用于轴承变工况特征集迁移。如图2所示,与 TCA 方法的高维希尔伯特空间相比,本文提出的基于映射的有限工况迁移学习方法的新映射空间为轴承的某一特定工况下的特征空间。

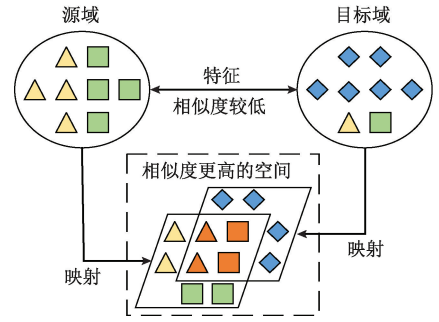


图1 迁移成分分析方法

Fig. 1 Transfer component analysis method

当我们选定某一工况作为参考工况,即作为源域,其他工况作为目标域,将其他工况下提取的特征集通过映射矩阵向参考工况特征集做迁移,即参考工况特征集既是源域,也是新数据空间。其他工况的特征集经映射迁移后与参考工况特征集有相似的数据分布,从而实现了变工况特征集迁移学习。

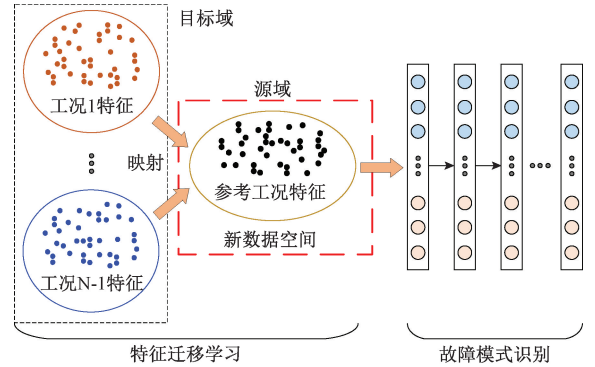


图2 基于映射的轴承变工况特征迁移学习

Fig. 2 Mapping-based transfer learning for bearing data features under variable working condition

理论上,可以通过矩阵变换的方法,将不同工况下的特征向量集各自通过一个映射矩阵,向参考工况下的特征向量集作映射。设共有 k 个试验轴承,每种工况下每个试验轴承选取同样的样本数量 n ,则同一工况下共有 $N = k \cdot n$ 个特征向量。由于参考工况的每个特征向量并不一致,因此采用一一对应的方式将当前工况下的特征向量集通过一个投影矩阵向参考工况下的特征集作映射,其结构如图3所示。

其中, $F_i \in R^{m \times N}$ 为工况 I 时的所有轴承样本的信号特征集, m 为单个特征向量维度, $F_{ref} \in R^{m \times N}$ 为参考工况下所有轴承样本的信号特征集也是不同工况特征向量映射的统一标准。具体的求解过程如下:

$$F_{i-1} * \omega^T = F_{ref-1} \quad (8)$$

其中, F_{i-1} 和 F_{ref-1} 分别为工况 I 和参考工况下的第 1 个特征向量, ω 为与 F_{i-1} 维度相同的矩阵。则映射矩阵

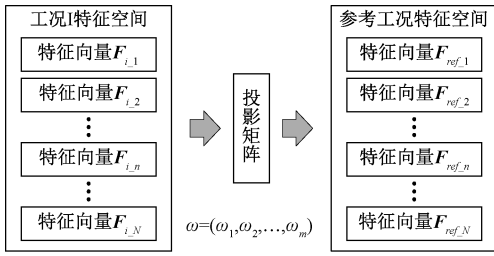


图3 变工况特征集映射模型

Fig. 3 Working condition features mapping model

ω 求解为:

$$\omega = ((F_{i,1})^{-1} * F_{ref,1})^T \quad (9)$$

则工况 I 下第一个特征向量 $F_{i,1}$ 与第 2 个特征向量 $F_{i,2}$ 存在以下关系:

$$F_{i,1} = F_{ref,1} * (\omega^T)^{-1} \quad (10)$$

$$F_{i,2} = F_{ref,2} * (\omega^T)^{-1} \quad (11)$$

由于同一工况下不同特征向量不完全相等,所以:

$$F_{i,1} \neq F_{i,2} \quad (12)$$

因此,不可能求解出一个单一矩阵 ω , 满足以下的映射关系:

$$F_i \cdot \omega^T = F_{ref} \quad (13)$$

因此,只能近似求解出一个矩阵 $\tilde{\omega}$, 使工况 I 的特征向量集在经其映射后与参考工况下的特征向量集误差尽量小,从而将问题转化为以下优化求解问题:

$$\min E = \sum_{n=1}^N (F_{ref,n} - F_{i,n} \cdot \tilde{\omega}^T) \quad (14)$$

其中, E 为映射误差函数, $\min E$ 即为求解 E 的最小误差。

1.3 深度自编码神经网络

自编码神经网络是一种无监督的机器学习模型,能根据自身的结构特性对输入信号进行编码与解码操作。AE 中的编码器能将输入数据编码为一组隐藏空间表征,然后解码器将隐藏空间表征数据重构得到输出数据,采用反向传播算法使输出数据与输入数据的重构误差最小。关于深度自编码神经网络的详细信息见参考文献[18]。

1.4 卷积神经网络

CNN 是一种多层前馈神经网络,通过多个单层卷积神经网络块的堆叠,能将输入数据转换为深层状态空间表征,最后将这些深层信息输入分类层,实现不同功能。其主要包含 4 个部分:卷积层、池化层、全连接层和分类层。卷积层通过局部卷积操作提取输入数据的局部特征;池化层将相似的特征合并为一个特征,从而减少网络参数,得到平移不变特征。全连接层将前一池化层得到的数据特征转换为一维数组并将之输入分类层以完成不

同的功能任务。关于卷积神经网络的详细信息见参考文献[5]。

2 基于监督式自编码器的变工况特征迁移

2.1 监督式自编码器

如图 4 所示,通过预设训练标签,将输入数据经过编码和解码操作使输出值与预设值尽可能相等,从而实现监督学习。与无监督的自编码器相比,监督式自编码器需要人为指定标签值。

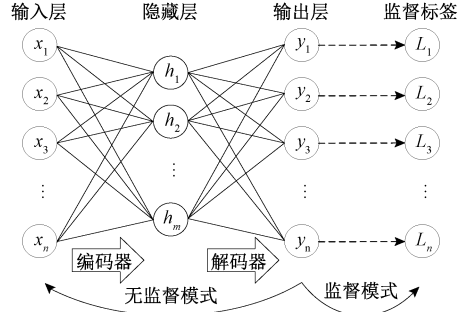


图4 监督式自编码器结构

Fig. 4 Supervised auto-encoder neural network architecture

由于指定了解码标签,SAE 的损失函数定义为解码器输出与指定解码标签的误差:

$$E_s(\omega, b) = \frac{1}{n} \sum_{i=1}^n \|y_i - L_i\|^2 \quad (15)$$

其中, y_i 为解码器输出数据, L_i 为预设解码标签值, n 为输入数据的维度。SAE 同样采用梯度下降法来调整各神经元的权重,直到 $E_s(\omega, b)$ 达到最小,模型收敛,模型训练完成。SAE 由于预设了解码标签值,误差函数的定义变为解码器输出值和预设解码标签值的映射误差,使得训练过程各个神经元权重调整的方向以及模型收敛的条件不同。

2.2 基于监督式自编码器的变工况特征迁移模型

图 3 所示变工况特征迁移模型结构与图 4 所示监督式自编码器类似,将图 4 所示 SAE 的隐藏层去除就可以得到基于监督式自编码器的变工况特征迁移模型,如图 5 所示。

SAE 可以通过引入非线性激活函数(activation function, AF)将图 5 中的线性映射矩阵转换为非线性映射,从而设计具有更强映射能力的监督式自编码器。在 SAE 不同位置引入激活函数,设计图 6 所示的基于 SAE 的线性或非线性的多工况特征迁移模型。

基于监督式自编码器的轴承变工况特征迁移模型建立流程如图 7 所示。设某轴承工况总数为 n ,记 $F = \{F_1, F_2, \dots, F_n\}$ 为所有工况下的轴承信号特征向量集。将工




图5 基于监督式自编码器的工况特征折算模型

Fig. 5 Supervised auto-encoder based the condition feature mapping model




图7 基于监督式自编码器的轴承变工况特征迁移模型建立

Fig. 7 SAE-based features transfer learning procedure

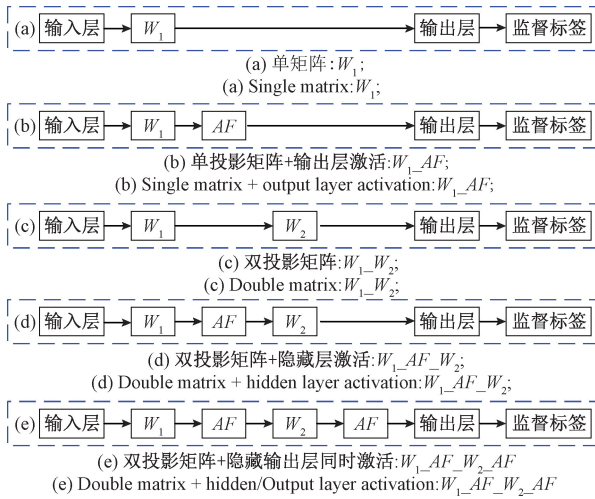


图6 自编码器映射模型设计

Fig. 6 Supervised auto-encoder structure design

况1得到的特征向量集作为自编码器的训练标签记为 $F_{ref} \in R^{m \times N}$, 将工况2的特征向量集 $F_2 \in R^{m \times N}$ 依次输入监督式自编码器, 按照1.2节中的方式向训练标签集 F_{ref} 做迁移映射, 得到工况2向参考工况的特征映射模型 W_{2-ref} , 再将剩余工况特征向量集输入监督式自编码器, 训练得到各自向参考工况的特征映射模型。除去参考工况, 可得 $n-1$ 个映射矩阵, 记为 $W = \{W_{2-ref}, \dots, W_{n-ref}\}$ 。对于某一工况下采集到的测试信号, 先判断其工况信息, 然后将其输入对应的映射模型实现变工况下向参考工况的特征映射迁移。

3 方案提出

3.1 基于监督式自编码器特征迁移和卷积神经网络的轴箱轴承多工况故障诊断

本文提出方法的主要研究思路为: 首先采用参考工况下的振动数据集完成单工况轴承故障诊断模型的训练与测试; 然后通过监督式自编码器得到不同工况下特征

向量集各自向参考工况特征集的映射矩阵。对于某一特定工况下的测试数据, 首先将其输入预训练的工况特征迁移模型, 实现向参考工况特征向量集映射迁移, 然后将映射后的工况特征集输入由参考工况数据集预训练的轴承故障诊断模型进行故障识别。

图8给出了基于SAE和CNN的高速列车轴箱轴承多工况故障诊断研究路线图, 主要包含信号采集和特征提取、模型训练和多工况故障模式识别3个环节。其中模型训练环节包括了两个模型的训练, 1) 以参考工况特征集来训练单工况CNN故障预测模型; 2) 以参考工况特征集为映射标签进行非参考工况特征集向参考工况特征集的迁移模型训练。

1) 参考工况 CNN 故障预测模型训练

采集参考工况下不同健康状态轴箱轴承的加速度信号, 构建训练样本和测试样本, 然后提取训练样本特征并对其进行归一化处理; 最后将归一化后的训练样本特征集 F_{ref} 输入 CNN 网络进行训练。利用误差反向传播调整模型, 当误差函数收敛时, 模型训练完毕。

2) 工况特征迁移模型训练

采集其他工况下的轴箱轴承加速度信号, 并分别构建对应工况的训练样本和测试样本; 然后提取样本特征并对其进行归一化处理; 最后以参考工况特征向量集为解码标签, 将当前工况的特征向量集作为输入, 依照2.2节中的方法进行工况迁移模型训练。SAE模型输出与解码标签之间的误差函数收敛时, 基于SAE的多工况特征迁移模型训练完成。

3) 轴箱轴承多工况故障模式识别

首先将不同工况下轴箱轴承测试样本特征集输入对应的预训练的工况迁移模型, 得到多工况特征迁移后的测试特征集; 然后将迁移后其他工况下的轴箱轴承测试样本特征集与参考工况测试样本特征集一起输入由参考工况特征集预训练的CNN故障预测模型, 得到轴承故障识别结果。

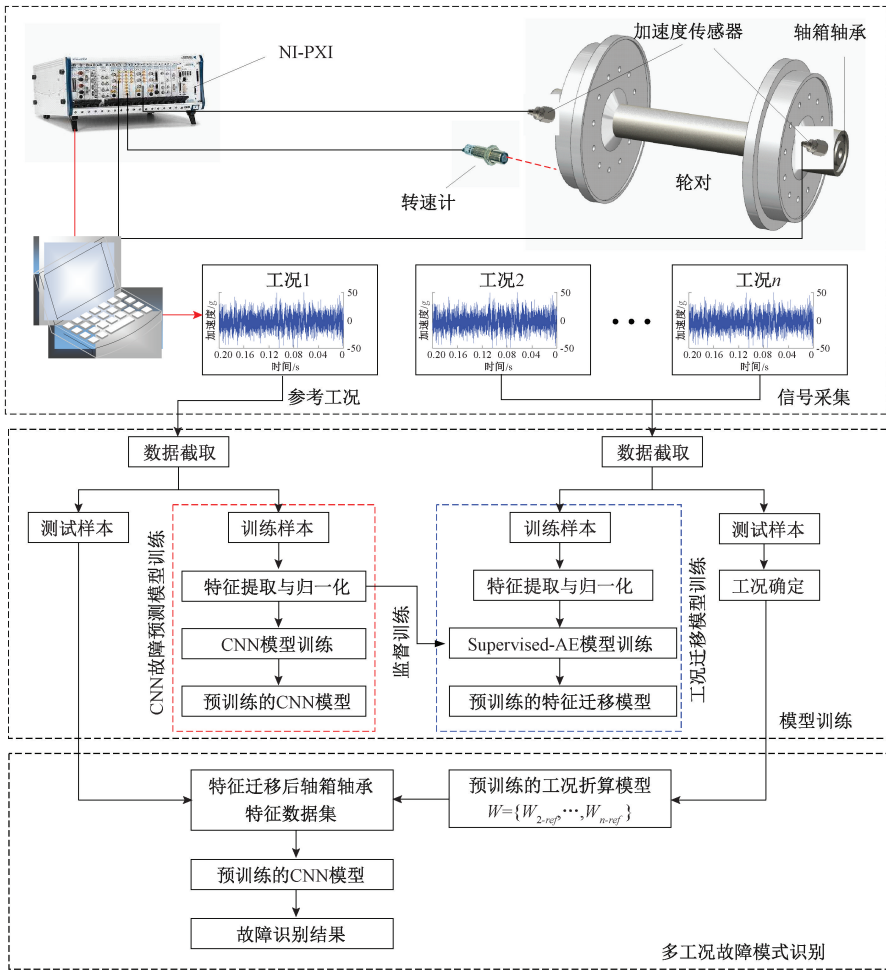


图 8 变工况轴箱轴承故障诊断研究流程图

Fig. 8 Flowchart of fault diagnosis of axle box bearing under variable working conditions

3.2 特征提取与归一化

轴承振动信号的时域和频域特征能够表征出轴承不同的故障类型和故障程度,这些时域和频域的特征组成的特征向量集可以作为构建轴承故障诊断模型的数据依据。基于文献[9],对于每个加速度信号样本,提取出包含 13 个时域特征和 16 个频域特征的共计 29 个特征量。特征提取后,为了消除由于特征量纲单位不同的影响,使每个特征值都对模型有所贡献,对特征值归一化处理。

3.3 监督式自编码器和卷积神经网络设计

SAE 的输出层维度应与输入层维度一致,由于每个样本提取出 29 个特征值,因此,即输入输出层维度大小为 $R^{1 \times 29}$,具体训练参数设置如表 1 所示。

表 1 监督式自编码器参数信息

Table 1 Specific setting parameters of SAE

参数	输入层	隐藏层	输出层	激活函数	学习效率
数值	1×29	1×29	1×29	Sigmoid	0.001

由于单个样本特征向量维度为 $F \in R^{1 \times 29}$,为了避免多次非线性变换后数据长度过短的问题,出于对输入特征向量长度及卷积深度的考虑,卷积核不宜过大,且不需要使用池化操作来降低卷积层的输出数据的维度。因此,设计的 CNN 模型中不包含池化层只有卷积层,其具体参数设置如表 2 所示,其中 n 为分类数,模型采用的激活函数为 ReLU 函数,初始学习率为 0.001。

表 2 CNN 参数信息

Table 2 Specific setting parameters of CNN

网络层类别	具体参数	输出特征大小
输入层	29 个特征向量	29×1
卷积层 C1	32 个 5×1 的卷积核,步长 1×1	25×1×32
卷积层 C2	64 个 5×1 的卷积核,步长 1×1	21×1×64
卷积层 C3	128 个 3×1 的卷积核,步长 1×1	18×1×128
卷积层 C4	256 个 3×1 的卷积核,步长 1×1	16×1×256
全连接层	4 096 个神经元	1×4 096
分类层	n 个神经元	n

4 试验验证

4.1 公开数据集验证

1) 数据描述

利用 CWRU (Case Western Reserve University) 轴承数据中心的数据集来验证本文提出的方法对于多工况轴承故障的诊断效果。如表 3 所示, 试验一共设置了 4 种工况。以 48 kHz 的采样频率采集了一共 10 类的轴承信号, 每种工况下载取 100 个数据样本, 每个样本包含 2 048 个数据点, 详细数据集描述如表 4 所示。

表 3 试验工况信息

Table 3 Experiments condition information

工况编号	电机负载/HP	电机转速/rpm
A	0	1 797
B	1	1 772
C	2	1 750
D	3	1 730

2) 单工况特征集训练的 CNN 模型多工况故障诊断

选择不同的工况作为源域来训练 CNN 故障预测模型, 即分别以每种工况下的训练样本构建训练特征集, 来训练对应工况的 CNN 故障预测模型。然后将所有工况的测试特征集输入预训练的 CNN 模型进行测试, 得到在不同工况下模型的测试准确率交叉验证结果。每种工况下, 共有 10 个轴承健康类型, 每类有 100 个数据样本共

表 4 数据描述

Table 4 Data description

故障部位	故障尺寸/mm	分类标签号	工况数	训练/测试样本量
正常	0	1	4	400/400
外圈	0.177 8	2	4	400/400
外圈	0.355 6	3	4	400/400
外圈	0.533 4	4	4	400/400
内圈	0.177 8	5	4	400/400
内圈	0.355 6	6	4	400/400
内圈	0.533 4	7	4	400/400
滚动体	0.177 8	8	4	400/400
滚动体	0.355 6	9	4	400/400
滚动体	0.533 4	10	4	400/400

计 1 000 个训练样本。重复 10 次试验, 诊断结果如表 5 所示。表 5 中, 源域中的训练准确率, 即单一工况下的基于 CNN 的轴承故障诊断模型的训练准确率都在 99.7% 以上。测试准确率即为目标域中对应工况测试特征集的测试准确率且都在 97% 以上。分别以每种工况作为源域训练得到的 CNN 轴箱故障诊断模型对于另外 3 种工况的测试数据集预测准确较低, 这 4 种工况下获得的 CNN 模型对所有工况的测试数据集的平均预测准确率都低于 80%。表 5 说明, 同种工况下, 基于 CNN 的模型能较为准确地诊断出的轴承故障, 但对于其他工况测试样本泛化能力较弱。

表 5 未特征迁移多工况故障诊断结果

Table 5 Multi-condition fault diagnosis results using unmigrated data features

源域		目标域				平均准确率
训练样本特征集	训练准确率	测试样本特征集				
		A	B	C	D	
A	100	99.2	62.8	57.4	57.9	69.3
B	99.8	58.6	98.6	80.7	58.7	74.1
C	99.7	55.1	84.1	97.2	73.5	77.5
D	99.8	59.5	78.6	77.5	98.2	78.4

3) 工况特征迁移效果

为了说明基于监督式自编码器的工况迁移效果, 选取工况 A 作为参考工况, 即参考工况特征为 hp0-1 797 rpm 工况下的特征, 对所有样本求取 29 个时域和频域特征, 归一化后, 将工况 B, C 和 D 的训练特征集输入工况特征映射模型向参考工况 A 对应样本的特征依次做迁移。不同的工况迁移模型误差结果如表 6 所示。与线性映射相比, 引入 AF 的非线性映射模型的训练误差与最大局部

映射误差都较小。其中, 双投影矩阵+隐藏层输出层同时激活 ($W_1_AF_W_2_AF$) 的工况迁移模型投影变换能力最强, 误差最小。


以 0.18 mm 故障尺寸下的外圈故障为例, 基于 $W_1_AF_W_2_AF$ 模型的特征迁移结果如图 9 所示。图中, 横坐标代表特征值序列, 纵坐标代表归一化后的特征幅值, 每一工况选取第一个特征向量样本进行展示, 不同颜色曲线代表不同工况下的特征序列。基于

表 6 不同工况迁移模型训练误差结果


Table 6 Training error of different feature transfer models

特征迁移模型结构	平均训练误差	最大局部投影误差
W_1	7.0×10^{-3}	0.31
W_1_AF	7.1×10^{-3}	0.29
$W_1_W_2$	5.9×10^{-3}	0.21
$W_1_AF_W_2$	2.1×10^{-3}	0.18
$W_1_AF_W_2_AF$	1.9×10^{-3}	0.12

$W_1_AF_W_2_AF$ 结构的特征迁移模型已经具有较好的特征迁移效果,在该模型中继续添加投影矩阵和激活函数将不会显著降低特征迁移误差且会增加计算负担。



(a)未迁移特征序列
(a) Feature sequence before transferring



(b)迁移后特征序列
(b) Feature sequence after transferring

图 9 外圈故障 0.18 mm 特征迁移前后对比

Fig. 9 Comparison of bearing feature sequence before and after transferring for outer race fault with 0.18 mm

表 8 特征经 $W_1_AF_W_2_AF$ 结构 SAE 迁移后 CNN 多工况故障诊断结果

Table 8 Diagnosis results of feature transfer model based on $W_1_AF_W_2_AF$ structure

源域		目标域				平均 准确率
训练样本特征集	训练准确率	A	B	C	D	
A	100	99.2	95.6	96.5	97.3	97.15
B	99.8	95.7	98.6	95.1	98.0	96.80
C	99.7	96.4	96.8	98.2	97.6	97.25
D	99.8	96.6	96.5	96.2	98.7	96.90

基于以上分析,本文提出的基于监督式自编码器特征迁移和卷积神经网络的轴承变工况故障诊断方法,在

选取工况 A 作为源域,将 B,C 和 D 工况的测试特征集输入具有不同结构的 SAE 进行迁移后,随机打乱后输入由 A 工况训练特征集预训练的 CNN 模型,得到 B,C 和 D 工况下的测试特征集迁移后的测试准确率和总体平均准确率,重复 10 次试验其结果如表 7 所示。未引入激活函数的 SAE 模型,其单矩阵和双矩阵的平均准确率提升最小分别为 80.3% 和 82%。而经双投影矩阵+隐藏层输出层同时激活的 SAE 迁移后的测试特征集测试准确率有了很大提升,平均准确率达到 97.15%。以上分析表明,基于监督式自编码器工况迁移能显著提升基于工况 A 为源域训练的 CNN 模型对于工况 B,C 和 D 的故障识别率。

表 7 工况 A 作为源域时不同监督式自编码器的效果对比
Table 7 Training accuracy of different SAE structure using the model trained using condition A features

SAE 结构	迁移后样本特征集测试准确率			平均 准确率
	B	C	D	
未迁移	62.8	57.4	57.9	59.4
W_1	89.7	84.5	72.4	80.3
W_1_AF	90.2	89.6	87.6	89.1
$W_1_W_2$	88.7	84.9	72.5	82.0
$W_1_AF_W_2$	91.0	96.1	99.2	95.4
$W_1_AF_W_2_AF$	95.6	96.5	97.3	97.15

为了进一步验证基于监督式自编码器和 CNN 对轴承变工况的故障诊断效果,分别以每种工况作为源域,将其他工况特征集通过结构为 $W_1_AF_W_2_AF$ 的监督式自编码器向其迁移后,输入对应源域的 CNN 故障预测模型,重复 10 次试验,测试准确率结果如表 8 所示。与表 5 相比,经过特征迁移后的,轴承故障识别率有了显著提升。不同源域得到的 CNN 模型经特征迁移后的平均测试准确率都达到了 96% 以上。其中,以 C 工况为源域,经特征迁移后平均测试准确率由 77.5% 提升至 97.25%。

CWRU 轴承数据集上取得了良好的效果。其中,基于投影矩阵+隐藏层输出层同时激活的监督式自编码器能较

好地实现不同工况下的特征集迁移。为了进一步验证本文提出方法的有效性,表9给出参考文献中基于迁移成分分析的不同轴承变工况故障诊断方法对于CWRU轴承数据集的测试准确率。由于噪声的影响,参考文献[15-20]中提出的变工况轴承故障诊断方法对于CWRU轴承数据集的测试准确率主要为94%~97%之间,本文提出的方法准确率可以达到97.15%,具有较高的轴承状态识别率。

表9 几种基于TCA的西储大学轴承数据集多工况故障诊断方法结果对比

Table 9 Comparisons of the proposed method with previous TCA-based studies adopting the CWRU dataset.

文献	方案	试验方案 (源域/目标域)	测试 准确率/%
[15]	特征迁移学习与卷积神经网络	A/BC	96.75
[16]	特征迁移学习与支持向量机	B/ACD	96.25
[17]	特征迁移学习与支持向量机	C/ABD	96.20
[18]	迁移成分分析与BP神经网络	A/BCD	91.30
[19]	自适应批量归一化与卷积神经网络	B/CD	96.79
[20]	特征迁移学习与K-最近邻分类	B/CD	93.80
本文 方法	特征迁移学习与卷积神经网络	A/BCD	97.15

4.2 高速列车轴箱轴承数据验证

1) 数据描述

轴箱轴承数据来自于高速列车系统集成国家工程实验室整车滚动综合性能试验台。如图10所示,整车滚动试验台主要包含驱动电机、主动轮、从动轮、加速度传感器和NI数据采集系统等。驱动电机带动主动轮旋转,驱动列车车轮转动模拟列车实际工况。




图10 整车滚动综合性能试验台示意图

Fig. 10 The sketch of rolling vibration test rig of train

8个在列车检修中收集到的轴箱轴承被安装在被试车上,在不同的工况下,以20 kHz的采样频率采集轴承振动信号。整周期工况设计如图11所示,图中转速曲线升速段共有9段恒速状态,选取100、150、200、250、300、350 km/h等共计6个组稳态工况下轴箱轴承振动数据作为分析用数据集。




图11 试验工况设计

Fig. 11 Experimental condition design for HST

试验用8个轴箱轴承由人工检视后确定的共计有6种健康状况,包含有正常状态、外圈和内圈复合故障、外圈和滚动体复合故障,以及3个不同故障等级的外圈故障。每种故障类型在不同工况下获取各100个训练和测试样本,详细的数据集说明如表10所示。

表10 数据描述

Table 10 Data description for HST

故障类型	故障尺寸	分类 标签号	工况数	训练/测试 样本数
正常	*	0	6	600/600
外圈和内圈故障	*	1	6	600/600
外圈和滚动体故障	*	2	6	600/600
外圈故障	轻微	3	6	600/600
外圈故障	中度	4	6	600/600
外圈故障	严重	5	6	600/600

2) 原始特征 CNN 的多工况轴承故障诊断

分别选择200、250、300和350 km/h作为源域来训练CNN故障预测模型,即分别以每种工况下的训练样本构建训练特征集,来训练对应工况的CNN故障预测模型。然后将所有6种工况的测试特征集输入预训练的CNN模型进行测试,得到模型在不同工况下的测试准确率交叉验证结果。每种工况下6个轴承健康类型,每类有100个数据样本共计600个训练样本。重复10次试验,诊断结果如表11所示。

表 11 高速列车原始特征 CNN 多工况故障诊断结果

Table 11 Multi-condition fault diagnosis results using unmigrated data features for HST

源域		目标域						平均准确率
训练样本特征集	训练准确率	测试样本特征集						
		100 km/h	150 km/h	200 km/h	250 km/h	300 km/h	350 km/h	
200 km/h	100	54.0	63.5	100	85.3	71.5	47.800	70.4
250 km/h	100	70.3	65.5	79.0	100	59.8	23.300	66.3
300 km/h	100	41.5	39.2	64.8	74.3	100	0.833	53.4
350 km/h	100	15.3	27.3	18.7	28.5	82.5	99.800	45.4

同一工况下,基于 CNN 的轴箱轴承故障诊断方法取得了优异的结果,4 种源域的训练准确率都达到了 100%,测试准确率都在 99.8% 以上。但对于其他工况的故障诊断准确率较低,4 种源域 CNN 故障诊断模型的平均测试准确率不高于 71%。这表明高速列车在不同车速下,轴箱轴承振动信号特征差异较大,单一工况训练的 CNN 故障诊断模型的泛化能力较差。

3) 工况迁移效果

选取 350 km/h 工况作为源域,即参考工况特征为列车 350 km/h 工况下的特征,对其他工况所有训练样本求取 29 个时域和频域特征,归一化后,输入工况特征迁移模型向标准工况下对应样本的特征做迁移。训练过程不同的工况迁移模型误差结果如表 12 所示。

表 12 不同工况迁移模型误差结果

Table 12 Training accuracy of feature transfer model based on different SAE structure for HST bearing

特征迁移模型	平均训练误差	最大局部投影误差
W_1	1.3×10^{-3}	0.21
W_1_AF	1.6×10^{-3}	0.23
$W_1_W_2$	1.1×10^{-3}	0.19
$W_1_AF_W_2$	2.9×10^{-4}	0.18
$W_1_AF_W_2_AF$	1.8×10^{-4}	0.11

工况迁移结果表明,基于双投影矩阵+隐藏层输出层同时激活自编码器模型对轴箱轴承训练特征集具有最优的工况迁移效果。以外圈严重程度故障为例,基于 $W_1_AF_W_2_AF$ 模型的特征迁移结果如图 12 所示。图中,横坐标代表特征值序列,纵坐标代表归一化后的特征幅值,每一工况选取第一个特征向量样本进行展示,不同颜色曲线代表不同工况下的特征序列。图 12 表明经过双投影矩阵+隐藏层输出层同时激活自编码器模型迁移后的由列车不同工况造成的轴箱轴承信号特征畸变得到了消除。

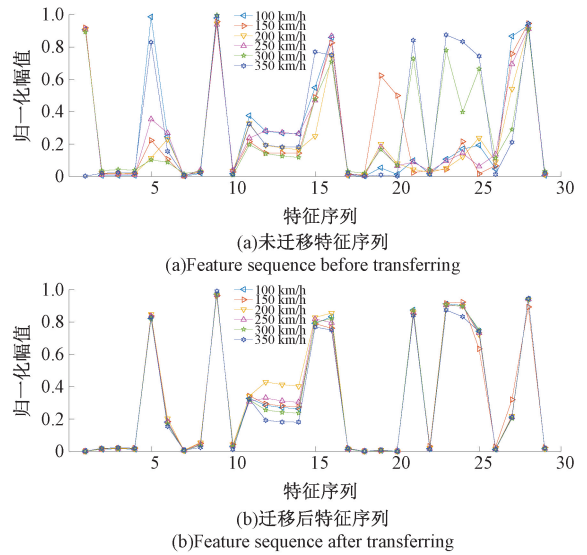


图 12 外圈严重故障特征序列迁移前后对比图

Fig. 12 Comparison of bearing feature sequence before and after transferring for severe outer race fault

分别以每种工况作为源域,将其他工况特征集通过双矩阵+隐藏层输出层同时激活的监督式自编码器向其迁移后,输入对应源域的 CNN 故障预测模型,测试准确率结果如表 13 所示。与表 10 相比,经过特征迁移后的,轴承故障识别率有了显著提升。4 种源域得到的 CNN 故障诊断模型对经特征迁移后测试样本集的平均测试准确率都达到了 98% 以上。其中,以 300 km/h 工况为源域,经特征迁移后平均测试准确率由 53.4% 提升至 99.4%。

4) 所提出变工况故障诊断车载应用架构

本文的目标是为高速列车开发一种有效的适用于变工况的轴箱轴承故障诊断方法并将其集成于动车组协同维修系统。本文提出的方法与高速列车协同维护的关系如图 13 所示。该框架主要包括实验室台架试验,车载系统运行和模型更新 3 个阶段。为了获得准确、高效的变工况故障诊断模型,在高速列车国家工程实验室进行了台架试验。利用列车滚动试验台采集的数据,训

表 13 特征迁移后 CNN 多工况故障诊断结果
Table 13 Multi-condition diagnosis results of CNN after feature transfer

源域		目标域						平均 准确率
训练样本 特征集	训练准确率	100 km/h	150 km/h	200 km/h	250 km/h	300 km/h	350 km/h	
200 km/h	100	99.80	99.1	100	98.8	100	98.2	99.3
250 km/h	100	100	99.6	100	100	100	97.0	99.4
300 km/h	100	100	100	100	100	100	96.2	99.4
350 km/h	100	95.33	98.0	99.8	99.5	99.8	99.8	98.7

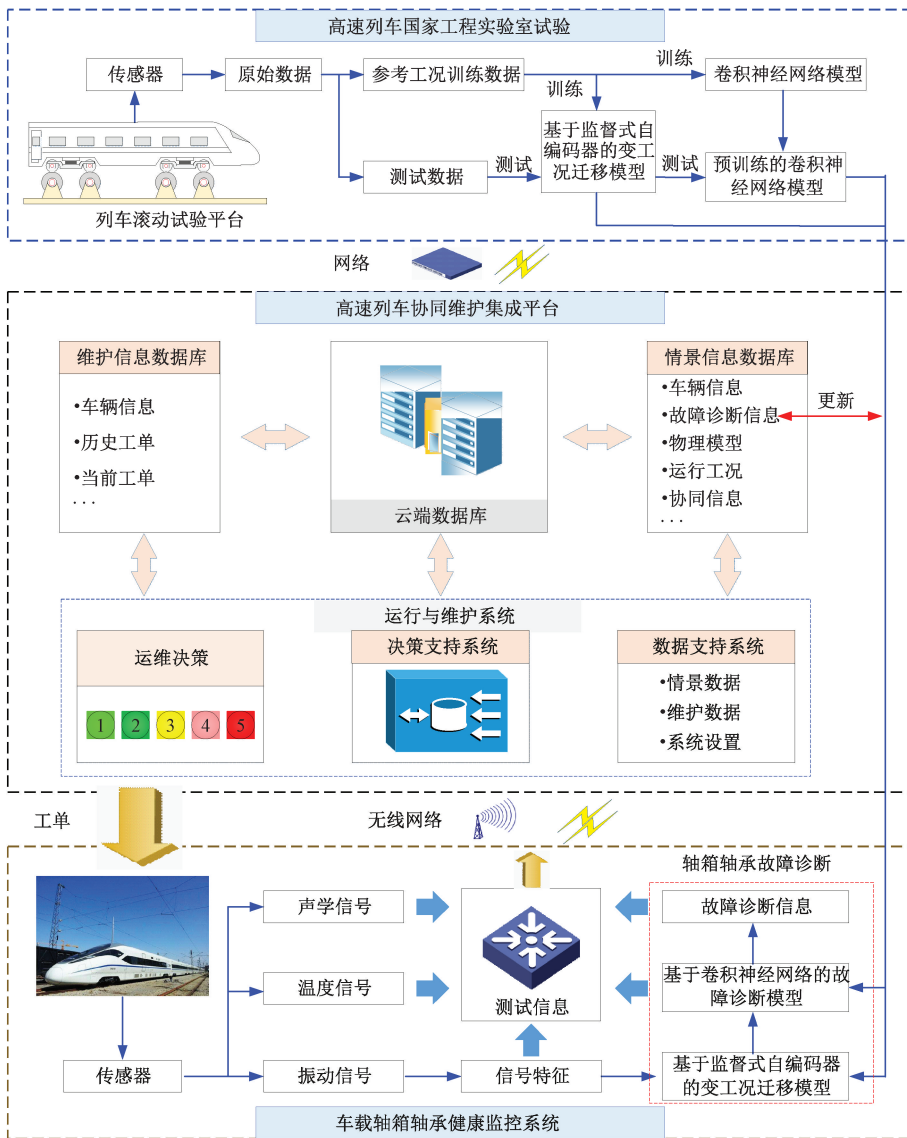


图 13 高速列车协同维护系统研究框架

Fig. 13 Collaborative maintenance system framework for HST

练了基于监督式自编码器特征迁移和卷积神经网络的高
速列车轴箱轴承变工况故障诊断模型。然后将训练好的

模型移植到车载轴承监测系统中,对轴箱轴承故障进行
监测。

如图 14 所示车载轴箱轴承健康监测系​​统诊断流程图拟选​​用时速 350 km/h 作为参考工况,则可用监督式自编码器训练分别得到 200, 250 和 300 km/h 工况下向参考工况 350 km/h 的特征映射矩阵,记为 $W_{200-350}$, $W_{250-350}$ 和 $W_{300-350}$ 。当车速在 350 km/h 时,信号特征直接输入预训练的 CNN 模型进行故障诊断;当处于其他运行速度时,先将信号特征输入对应的基于 SAE 的工况迁移模型映射后再输入预训练的 CNN 模型进行故障诊断,同时车载系统通过网络将相关数据上传至高速列车协同维护集成平台。

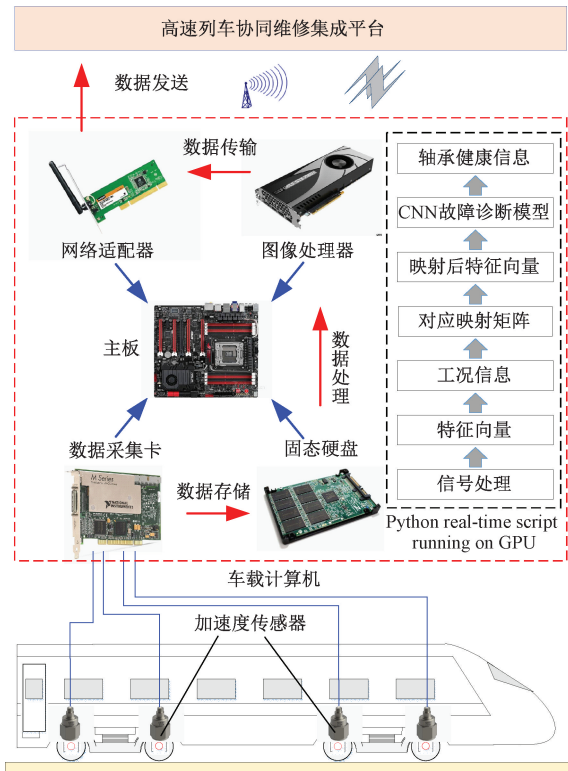


图 14 车载轴箱轴承变工况故障诊断技术途径

Fig. 14 The technical route of fault diagnosis for high-speed train axle-box bearings

轴箱轴承 CBM 系统的建立不是一个从最初的设计就能顺利、完美实施的过程,而是一个不断升级和丰富预测知识和数据库的过程。在本文提出方法实施之初,不太可能收集大量数据并产生足够全面的知识。然而,轴箱轴承状态监控执行过程中,数据库和知识库可以得到改进和丰富,进而建立一个可靠的适用于轴箱轴承健康监测的模型。

5 结 论

为了实现高速列车轴箱轴承变工况故障诊断,本文将无监督的自编码器改造为监督式自编码器,提出了基

于监督式自编码器和卷积神经网络的有限变工况轴承故障检测方法。该方法将不同工况下提取的信号特征向量集通过监督式自编码器向标准工况下的信号特征做迁移,再将迁移后的信号特征输入由参考工况训练集特征预训练的卷积神经网络进行故障识别。通过对西储大学轴承数据集和高速列车实测数据集的分析,与直接将原始特征输入卷积神经网络的故障识别准确率相比,运用监督式自编码器特征迁移后的故障识别准确率有了大幅提升。试验分析结果表明该方法能有效消除工况变化引起的故障特征偏移,通过将提出的方法嵌入高速列车协同维护系统,实现变工况的高速列车轴箱轴承故障的实时在线诊断。

参考文献

- [1] LEI Y, YANG B, JIANG X, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap [J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.
- [2] RANDALL R B, ANTONI J. Rolling element bearing diagnostics—A tutorial [J]. Mechanical Systems and Signal Processing, 2011, 25(2): 485-520.
- [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] ZHANG W, LI C, PENG G, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. Mechanical Systems and Signal Processing, 2018, 100: 439-453.
- [5] 董勋, 郭亮, 高宏力, 等. 代价敏感卷积神经网络: 一种机械故障数据不平衡分类方法 [J]. 仪器仪表学报, 2019, 40(12): 205-213.
DONG X, GUO L, GAO H L, et al. Cost sensitive convolutional neural network: A classification method for imbalanced data of mechanical fault [J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 205-213.
- [6] CHEN Z, GRYLLIAS K, LI W. Mechanical fault diagnosis using convolutional neural networks and extreme learning machine [J]. Mechanical Systems and Signal Processing, 2019, 133.
- [7] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法 [J]. 振动与冲击, 2018, 37(19): 124-131.
LI H, ZHANG Q, QIN X R, et al. Fault diagnosis

- method for rolling bearings based on short-time Fourier transform and convolution neural network[J]. *Journal of Vibration and Shock*, 2018, 37(19): 124-131.
- [8] CHEN Z, LI C, SANCHEZ R, et al. Gearbox fault identification and classification with convolutional neural networks[J]. *Shock and Vibration*, 2015, 2015: 1-10.
- [9] LUO H, BO L, PENG C, et al. Fault diagnosis for high-speed train axle-box bearing using simplified shallow information fusion convolutional neural network [J]. *Sensors*, 2020, 20(17): 4930.
- [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] 彭畅. 旋转机械轴承振动信号分析方法研究[D]. 重庆:重庆大学, 2014.
- PENG CH. Vibration signal analysis of bearings in the rotating machinery [D]. Chongqing: Chongqing University, 2014.
- [12] 张焱, 何妹锁, 王平, 等. 无转速计下变工况滚动轴承故障特征量化表征提取[J]. *仪器仪表学报*, 2021, 41(8): 104-114.
- ZHANG Y, HE SH B, WANG P, et al. Tachless quantitative characterization of rolling bearing fault feature under varying conditions [J]. *Chinese Journal of Scientific Instrument*, 2021, 41(8): 104-114.
- [13] TANG Z, BO L, LIU X, et al. A semi-supervised transferable LSTM with feature evaluation for fault diagnosis of rotating machinery [J]. *Applied Intelligence*, 2022, 52(2): 1703-1717.
- [14] 王震, 黄如意, 李霁蒲, 等. 一种用于故障分类与预测的多任务特征共享神经网络[J]. *仪器仪表学报*, 2019, 40(7): 172-180.
- WANG ZH, HUANG R Y, LI J P, et al. Multi-task feature sharing neural network used for fault diagnosis and prognosis [J]. *Chinese Journal of Scientific Instrument*. 2019, 40(7): 172-180.
- [15] JIN G, XU K, CHEN H, et al. A novel multi-adversarial cross-domain neural network for bearing fault diagnosis[J]. *Measurement Science & Technology*, 2021, 32(5): 055102.
- [16] 康守强, 刘哲, 王玉静, 等. 基于改进 DQN 网络的滚动轴承故障诊断方法[J]. *仪器仪表学报*, 2021, 42(3): 201-212.
- KANG SH Q, LIU ZH, WANG Y J, et al. A fault diagnosis method of rolling bearing based on the improved DQN network [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(3): 201-212.
- [17] 胡明武. 基于迁移学习的变工况下滚动轴承故障诊断方法研究[D]. 哈尔滨:哈尔滨理工大学, 2019.
- HU M W. Research on fault diagnosis method of rolling bearings under variable working conditions based on transfer learning [D]. Harbin: Harbin University of Science and Technology, 2019.
- [18] SUN M, WANG H, LIU P, et al. A sparse stacked denoising autoencoder with optimized transfer learning applied to the fault diagnosis of rolling bearings [J]. *Measurement*, 2019, 146: 305-314.
- [19] HU T, TANG T, LIN R, et al. A simple data augmentation algorithm and a self-adaptive convolutional architecture for few-shot fault diagnosis under different working conditions [J]. *Measurement*, 2020, 156: 107539.
- [20] XU W, WAN Y, ZUO T, et al. Transfer learning based data feature transfer for fault diagnosis [J]. *IEEE Access*, 2020, 8: 76120-76129.
- [21] 杜江红, 郭军强. 基于列车速度的行车许可计算方法研究[J]. *铁路通信信号工程技术*, 2020, 17(6): 90-94.
- DU J H, GUO J Q. Research on calculation method of movement authority based on train speed [J]. *Railway Signaling & Communication Engineering*, 2020, 17(6): 90-94.
- [22] SYMONDS N, CORNI I, WOOD R J K, et al. Observing early stage rail axle bearing damage [J]. *Engineering Failure Analysis*, 2015: 216-232.
- [23] VALE C, BONIFÁCIO C, SEABRA J, et al. Novel efficient technologies in europe for axle bearing condition monitoring – the MAXBE project [J]. *Transportation Research Procedia*, 2016, 14: 635-644.
- [24] 陈皓. 基于经验模态分解和遗传神经网络的轨道车辆轴承故障诊断研究[D]. 南京:南京理工大学, 2013.
- CHEN H. Research on railway vehicle rolling bearing fault diagnosis based on experience model decomposition and RBF neural network [D]. Nanjing: Nanjing University of Science and Technology, 2013.
- [25] 李永健. 高速列车轴箱轴承智能故障诊断技术研究

究[D]. 成都:西南交通大学, 2017.

LI Y J. Research on intelligent fault diagnosis technique of axle box bearing of high speed train [D]. Chengdu: Southwest Jiaotong University, 2017.

- [26] 钟祥鸣. 高速列车轴承故障诊断监测系统开发[D]. 大连:大连交通大学, 2018.

ZHONG X M. Development of fault diagnosis and monitoring system for high-speed train bearings [D]. Dalian: Dalian Jiaotong University, 2018.

- [27] 赵聪聪, 白杨, 刘玉梅, 等. 基于改进安全域的轴箱轴承状态监测[J]. 西南交通大学学报. 2020, 55(4): 889-895.

ZHAO C C, BAI Y, LIU Y M, et al. Condition monitoring of axle box bearing based on improved safety region [J]. Journal of Southwest Jiaotong University, 2020, 55(4): 889-895.

- [28] 姚德臣, 刘恒畅, 杨建伟, 等. 基于深度学习的城轨列车轴承复合故障诊断研究[J]. 铁道学报, 2021, 43(6): 37-44.

YAO D CH, LIU H CH, YANG J W, et al. Diagnosis of compound faults of bearings of urban rail train based on deep learning model [J]. Journal of the China Railway Society, 2021, 43(6): 37-44.

作者简介



罗宏林, 2013年于重庆大学获得学士学位, 现为重庆大学博士研究生, 主要研究方向为振动信号处理和设备故障诊断。

E-mail: 20097477@cqu.edu.cn

Luo Honglin, received his B.Sc. degree from Chongqing University in 2013. He is currently pursuing his Ph.D. degree at Chongqing University. His main research interests include intelligent test and instruments and fault detection and diagnosis.



柏林(通信作者), 2004年于重庆大学获得博士学位, 现为重庆大学教授、博士生导师, 主要研究方向为非平稳信号处理, 机械故障诊断、状态评估与预测技术。

E-mail: bolin0001@aliyun.com

Bo Lin (Corresponding author), received his Ph.D. degree from Chongqing University in 2004. He is currently a professor at Chongqing University. His research interests include noise and vibration, measurement technology, and fault diagnosis.



侯东明, 2016年于陕西理工大学获得硕士学位, 现为北京交通大学博士研究生, 主要研究方向为机械故障诊断, 状态评估与预测技术。

E-mail: 18116010@bjtu.edu.cn

Hou Dongming, received his M.Sc. degree from Shaanxi University of Technology in 2016. He is currently a Ph.D. candidate at Beijing Jiaotong University. His main research interests include mechanical fault diagnosis, condition assessment and prediction techniques.



彭畅, 2014年于重庆大学获得博士学位, 现为中车青岛四方机车车辆股份有限公司高级工程师, 主要研究方向为振动信号处理, 机械故障诊断。

E-mail: pengchang@cqsf.com

Peng Chang, received his Ph.D. degree from Chongqing University in 2014. He is currently a research engineer in the National Engineering Laboratory for High-Speed Train at CRRC Qingdao Sifang Co., Ltd., His main research interests include state monitoring, fault diagnosis and prediction, and operation and maintenance of the high-speed train.