http://bhxb.buaa.edu.cn jbuaa@buaa.edu.cn
DOI: 10.13700/j.bh.1001-5965.2022.0719

基于迁移学习的齿轮箱开放集跨工况故障诊断

马翔[1,2]，许庶[1,2]，尚芃超[1]，马剑[1,2,3,4,*]，周汝志[5]

(1. 北京航空航天大学 可靠性与系统工程学院，北京 100191；2. 北京航空航天大学 可靠性与环境工程技术重点实验室，北京 100191；3. 北京航空航天大学 可靠性工程研究所，北京 100191；4. 北京航空航天大学 国际创新研究院，杭州 311115；5. 上海卫星工程研究所，上海 201109)

摘 要：随着工业与航空航天技术的不断发展，齿轮箱等旋转机械的工况与故障模式逐渐趋于多样化、复杂化，可靠性与安全性问题日益突出，大量工况数据缺乏故障标签，且不同工况间故障模式不对称，迫切需要研究有效的故障诊断方法。以齿轮箱为案例验证对象，设置跨工况和开放集故障诊断场景，针对目标工况故障标签匮乏的问题，提出利用迁移学习将源工况的知识迁移到目标工况，利用交叉熵分类损失函数对已知故障类型进行识别的方法；针对跨工况条件下故障模式不对称的开放集问题，提出利用卷积神经网络提取工况间的相似数据特征，利用二分类损失函数对目标工况的已知类与未知类进行分类的方法。提出联合损失函数，训练诊断模型，实现故障特征从源域到目标域的联合迁移。案例分析结果表明：所提方法能够实现开放集情况下的跨工况故障诊断，且平均诊断准确度在90%以上。

关 键 词：旋转机械；数据驱动；开放集；迁移学习；故障诊断

中图分类号：V240.2

文献标志码：A **文章编号**：1001-5965(2024)05-1753-08

随着现代工业技术的不断发展，机电设备逐渐成为一个智能化、大型化和复杂化的有机整体，在航空、航天等领域得到了广泛的应用[1]。同时，随着设备复杂度与研制成本的提高，结合避免灾难性事故的需求，工业技术对机电设备的可靠性和安全性提出了更高的要求。齿轮作为现代机械设备中最常见的一种传动方式之一，在实际运转过程中，会发生断裂、胶合等情况，导致设备失去工作能力，因此，采用合理方式判断齿轮是否失效对提高设备可靠性与安全性有着重要的意义[2]。基于避免灾难性事故的需求，以及设备管理发展的客观需求，故障诊断技术不断发展起来。故障诊断技术能够及时地对齿轮各种故障状态做出诊断，便于预防或消除由齿轮故障引起的机电设备失效[3]。随着工业设备传感器监测数据的增多，依赖大量齿轮振动信号的数据挖掘技术不断发展，同时也为基于数据驱动的故障诊断技术提供了思路与技术途径，使得开发人员可以在无须或无法精确解析系统模型的情况下，通过计算机利用数据驱动算法对海量数据进行处理、解析，最终完成基于数据驱动的故障诊断[4]。

目前，常用的基于数据驱动的齿轮箱故障诊断方法更专注于设备运行参数、环境变量等较为固定的单一工况。但在齿轮箱实际运行过程中，由于设备个体、使用环境、工作时间、执行任务等因素的多样性，导致实际运行工况复杂多变，考虑到时间和成本的影响，只能针对少量工况进行故障模式分析和确定，故障标签获取困难[5]，存在齿轮箱跨工况故障诊断问题；同时，不同工况之间由于工作条件的不同也会导致故障类型、数量及发生概率差异明显[6]，表现为目标工况既包含源工况的所有已知故障模式，又包含源工况不具备的未知故障模式，即

收稿日期：2022-08-17；**录用日期**：2022-09-23；**网络出版时间**：2022-12-28 12:13
网络出版地址：link.cnki.net/urlid/11.2625.V.20221227.1135.001
基金项目：中央高校基本科研业务费专项资金 (YWF-22-L-516)；民用飞机专项科研 (MJ-2018-Y-58)
* **通信作者**. E-mail：09977@buaa.edu.cn

引用格式：马翔，许庶，尚芃超，等. 基于迁移学习的齿轮箱开放集跨工况故障诊断 [J]. 北京航空航天大学学报，2024，50（5）：1753-1760.
MA X，XU S，SHANG P C，et al. Fault diagnosis of gearbox under open set and cross working condition based on transfer learning [J]. Journal of Beijing University of Aeronautics and Astronautics，2024，50（5）：1753-1760（in Chinese）.

开放集场景。本文以工业齿轮箱为案例验证对象，采用加速度传感器采集齿轮箱振动数据信号，齿轮箱故障诊断问题具体可表示为：源领域包含正常、故障1、故障2等3种故障模式，标签已知；目标领域包含正常、故障1、故障2和未知故障等4种故障模式，标签未知；借助源领域充足标签进行故障知识迁移，对目标领域的数据样本进行故障模式识别与分类。

跨工况故障诊断需要利用源工况故障标签充足这一重要优势训练故障诊断模型，但跨工况故障诊断的难点在于如何使得训练后的模型能够适配于目标工况，即在一定程度上保证源工况和目标工况是相似的[7]。针对这一问题，考虑到迁移学习广泛应用于不同工况场景，可以解决标注数据稀缺问题，具有故障知识跨领域应用的特性，本文采用迁移学习的方法，通过利用样本间的相似度，在源工况中筛选出可迁移样本，并将可迁移样本的故障信息应用到缺乏故障标签的目标工况，从而实现对目标工况的故障诊断。借助迁移学习方法，使得源工况训练得到的模型可以作为目标工况训练模型的起点，很大程度上降低了故障诊断模型训练成本，并且能够保证模型的准确性。

迁移学习本质上是一种从相似任务中学习知识的思想，而知识迁移只有在适当的情况下才有可能实现，因此，迁移学习有应用上限，存在领域差异越大迁移效果越差的局限性。考虑到不同工况故障模式差异可能导致迁移学习效果不佳[8]，需要进一步关注开放集问题，即在测试过程中存在遇到训练中没有出现的新故障类型的可能性。开放集问题需要通过特定机制来识别训练过程中不包含的故障类型，通过将交叉验证的概念扩展到跨工况故障诊断，并设定源工况训练集（只包含已知故障种类）、目标工况测试集（包含已知故障种类与未知故障种类）来模拟开放集场景。

近年来，跨工况条件下的齿轮故障诊断方法逐渐成为研究重点。Lee等[1]以最大平均差异为距离度量实现边缘域融合，最小化源域分类器中的交叉熵损失及源域和目标域数据之间的最大平均差异；为解决专注于边缘分布对齐的传统方法效率较低的问题，Zhang等[3]引入对抗性学习提取广义特征，利用实例级加权机制反映具有已知健康状态的测试样本的相似性；王廷轩等[5]通过连续小波变换（continuous wavelet transform, CWT）算法将振动信号转化为二维信号，将故障信号通过核函数映射到再生希尔伯特空间，以多核最大均值差异（multiple kernel maximum mean discrepancy, MK-MMD）距离为度量标准，提高了不同工况下跨平台滚动轴承故障诊断容错率和诊断精度；张根保等[7]利用栈式稀疏自动编码器（sparse autoencoder, SAE）和柔性最大值函数Softmax回归，引入高阶KL散度（high-order Kullback-Leibler, HKL）训练域自适应能力，实现从具有大量已知故障标签的工况迁移到故障标签匮乏的相似工况；刘应东等[8]将联合分布适应（joint distribution adaptation, JDA）算法与K-最近邻（K-nearest neighbors, KNN）分类算法相结合，通过Fisher线性判别分析（Fisher's linear discriminant analysis, FLDA）方法计算特征权重；文献[9]借助仿真平台的传输故障数据训练单一故障诊断模型，并将模型参数迁移至风电机组齿轮箱的复合故障诊断模型中，进行风电机组齿轮箱故障诊断；陈仁祥等[10]提出一种深度置信网络（deep belief network, DBN）迁移学习方法，利用辅助标记数据训练DBN预模型，再利用少量的目标标记样本微调DBN预模型的网络权重和偏置值，实现从源域到目标域的迁移；Cao等[11]提出了一种基于深度卷积神经网络的迁移学习体系结构，包括用于自动提取特征的深度神经网络和用于对特征进行分类的分类器，使用基准齿轮系统的实验数据进行实例分析；Ma等[12]提出了一种基于AlexNet的转移学习卷积神经网络（transfer learning with convolutional neural networks, TLCNN）用于轴承故障诊断，利用二维图像表示方法将振动信号转换为二维时频图像，通过提出的TLCNN模型提取二维时频图像的特征，为故障分类提供条件，并采用t-分布随机邻域嵌入（t-distributed stochastic neighbor embedding, t-SNE）方法对特征学习过程进行可视化；Chen等[13]提出了一种域对抗传输网络（domain adversarial transfer network, DATN），利用特征学习网络学习源域和目标域的层次表示，将源任务中学习到的网络权重迁移到目标任务，引入域对抗训练技术，以最小化源分布和目标分布之间的差异；文献[14]提出了一种基于双对抗学习（domain adversarial neural networks, DANN）的开放集域自适应网络，辅助领域鉴别器为单个目标样本分配相似性权重，以区分已知和未知故障模式，并采用加权对抗学习来选择性地适应领域分布。

上述研究解决了跨工况故障诊断中面临的主要问题，即故障标签从源工况到目标工况的迁移，但实际情况中，往往由于工况之间的故障模式种类差异过大，导致工况间不具备迁移的条件[15]。

由于卷积神经网络（convolutional neural network, CNN）在故障诊断方法研究中得到了广泛的研究，具有强大的鲁棒和稳定特征提取能力[16-22]。因此，

本文在考虑了跨工况条件的同时, 对开放集问题进行研究, 提出了一种基于深度卷积神经网络的开放集跨工况故障诊断模型, 提取原始振动数据的故障特征, 考虑到开放集故障模式不对称的特点, 通过引入未知故障识别损失函数与已知故障分类损失函数, 同时识别并标记目标域数据中的未知类故障和已知类故障, 具备解决开放集问题的能力。本文方法不仅可实现跨工况已知故障分类, 还在此基础上进一步实现了开放集场景未知故障的识别, 诊断准确度可达 97.5%, 为开放集条件下的跨工况故障诊断问题提供了可行的解决方法。

1　开放集故障诊断问题分析及场景设计

封闭集和开放集数据的跨工况迁移诊断任务场景对比如图 1 所示。

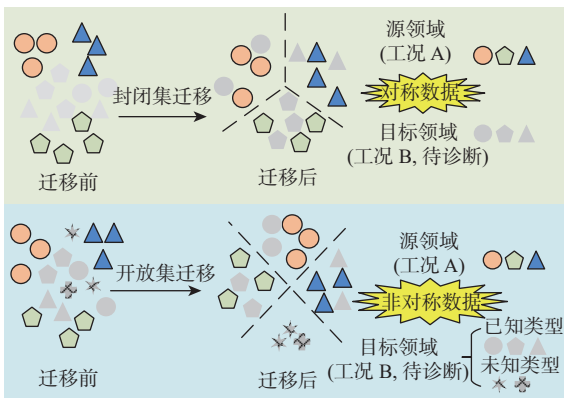


图 1　封闭集和开放集迁移学习分类任务场景对比

Fig. 1　Scenario comparison of closed-set and open-set migration learning classification tasks

在封闭集数据迁移场景中, 源领域数据 (工况 A) 有标签, 目标领域数据 (工况 B) 无标签, 但是 2 种运行工况下数据的故障类型完全一致, 数据类型对称。传统的迁移学习方法通过将目标域特征映射到源域特征空间进行对齐, 即能实现工况 B 数据的故障诊断; 而对于开放集数据迁移场景, 源领域数据 (工况 A) 有标签, 目标领域数据 (工况 B) 无标签, 并且工况 B 数据具有新的(未知)故障模式, 数据类型不对称[15]。在源工况和目标工况数据标签不对称的情况下, 现有的迁移学习方法在特征迁移对齐时, 由于工况 B 数据存在新的故障模式数据, 无法将新的故障模式特征映射到源域特征空间, 从而具有一定的非对称(开放)性。因此, 在使用迁移学习进行特征映射前, 需要对目标域的未知故障类型进行识别[16], 方法是通过共享特征选择的方式找到 2 个领域公共的故障特征, 其他非共享特征即为每个域的特征, 从而识别出未知故障; 再对领域间的共享特征进行迁移, 以实现已知故障的分类。

2　基于 J-CNN 的开放集跨工况迁移故障诊断方法

在迁移学习任务中, 带标记的源工况数据集可表示为 $D_S=\{\boldsymbol{X}_S,\boldsymbol{Y}_S\}$, $\boldsymbol{X}_S$为源工况的样本数据, $\boldsymbol{Y}_S$为相应的已知数据标签, 未标记的目标工况数据集可表示为 $D_T=\{\boldsymbol{X}_T,\boldsymbol{Y}_T\}$, $\boldsymbol{X}_T$为目标工况的样本数据, $\boldsymbol{Y}_T$为相应的未知数据标签。则开放集场景的变量符号表示为: 假设 $\boldsymbol{X}_S=\{\boldsymbol{x}_{s1},\boldsymbol{x}_{s2},\cdots,\boldsymbol{x}_{sk}\}$具有 k 种类型, $\boldsymbol{x}_{sj}(0<j\leqslant k, j\in\mathbf{N}^*)$为第 j 种数据类型, 而 $\boldsymbol{X}_T=\{\boldsymbol{x}_{t1},\boldsymbol{x}_{t2},\cdots,\boldsymbol{x}_{tk},\boldsymbol{x}_{t(k+1)}\}$具有 k+1 种数据类型, $\boldsymbol{x}_{ti}(0<i\leqslant k+1, i\in\mathbf{N}^*)$为第 i 种数据类型, $\boldsymbol{x}_{t(k+1)}$代表目标工况中独有的数据类型。

基于迁移学习的开放集跨工况故障诊断方法的实施思路为: 找到源工况和目标工况之间的相似数据特征, 从而识别出目标工况特有的未知类故障; 通过迁移源工况和目标工况间的共享特征, 利用 Softmax 分类函数将目标工况的数据分为 k 种已知的故障类型及 1 种未知的故障类型; 通过反向传播模型参数, 最小化已知类型和未知类型数据的联合分类损失, 完成此故障诊断模型的训练。根据上述思路, 本文提出基于联合损失函数的卷积神经网络 (convolution neural network based on joint loss function, J-CNN)。J-CNN 是一种利用联合损失函数对网络参数进行调整, 包含卷积计算且具有深度结构的前馈神经网络。其中, 联合损失函数由二分类损失函数与多分类损失函数组成。J-CNN 方法通过构建联合损失函数并进行反向传播, 达到综合训练网络模型对一种未知故障类型的识别能力和对 k 种已知故障类型的分类能力的目的。

基于 J-CNN 的开放集跨工况迁移故障诊断方法流程如图 2 所示。

基于 J-CNN 的开放集跨工况迁移故障诊断模型主要由特征提取模型和分类模型 2 部分构成。特征提取模型 $\boldsymbol{F}$ 主要由卷积层和池化层构成, 从不同领域的原始数据中提取高维故障特征, 输出记为 $\boldsymbol{F}(\boldsymbol{x})$; 特征分类模型 $\boldsymbol{C}$ 主要由全连接层和 Softmax 分类层构成, 将提取的特征分为 k+1 种类别, 分别对应 k 种已知类型和所有未知类型。由特征分类模型 $\boldsymbol{C}$ 得到的 k+1 维输出向量记为 $\boldsymbol{C}(\boldsymbol{F}(\boldsymbol{x}))=\{l_1, l_2,\cdots,l_{k+1}\}$, 每一维对应不同的数据种类; 通过 Softmax 函数可以将 k+1 维输出向量转化为 0~1 之间概率值, 表示样本被分为相应类型的概率。因此, 样本 $\boldsymbol{x}$ 属于第 i 种类型的概率可表示为

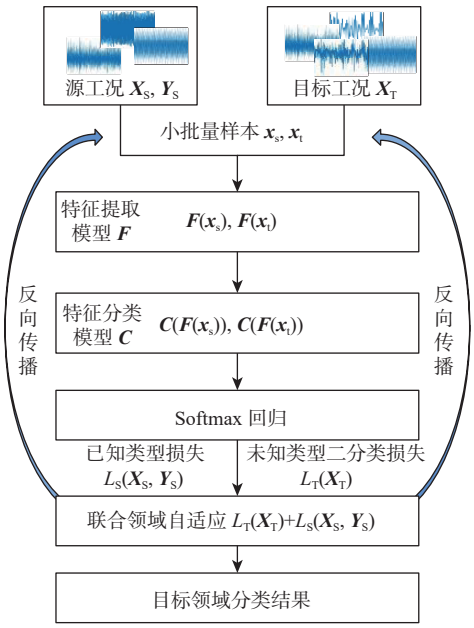


图2 基于J-CNN的开放集跨工况迁移故障诊断方法流程

Fig. 2 J-CNN-based open-set cross-condition migration fault diagnosis methodology process

$$p(\boldsymbol{y}=i|\boldsymbol{x})=\frac{\exp(l_i)}{\sum_{i=1}^{k+1}\exp(l_i)} \qquad i=1,2,\cdots,k+1 \tag{1}$$

式中：第k+1维输出为$p(\boldsymbol{y}=k+1|\boldsymbol{x})=t$，表示该样本属于未知类型的可能性大小为$t$。采用小批量样本训练方式和反向传播算法迭代更新模型的权重参数，获得目标工况数据的分类标签。

开放集数据迁移的难点在于识别目标工况中未知的数据类型。由于源工况中缺少相应类型的数据，源工况数据不能直接与目标工况未知的数据类型建立正确的映射关系。对于源工况数据$(\boldsymbol{X}_S,\boldsymbol{Y}_S)$，定义交叉熵分类损失函数为

$$L_S(\boldsymbol{X}_S,\boldsymbol{Y}_S)=-\sum\log(p(\boldsymbol{y}=\boldsymbol{y}_s|\boldsymbol{x}_s)) \tag{2}$$

$$p(\boldsymbol{y}=\boldsymbol{y}_s|\boldsymbol{x}_s)=\boldsymbol{C}(\boldsymbol{F}(\boldsymbol{x}_s)) \tag{3}$$

$L_S(\boldsymbol{X}_S,\boldsymbol{Y}_S)$表示模型对源工况数据分类的损失大小；对于目标领域数据$\boldsymbol{X}_T$，定义未知类型数据的二分类损失函数为

$$L_T(\boldsymbol{X}_T)=-\sum t\log(p(\boldsymbol{y}=k+1|\boldsymbol{x}_t))-\sum(1-t)\log(1-p(\boldsymbol{y}=k+1|\boldsymbol{x}_t)) \tag{4}$$

$L_T(\boldsymbol{X}_T)$表示将样本$\boldsymbol{X}_T$标记为未知类型而可能产生的分类损失大小。

在开放集数据条件下，为正确区分目标工况和源工况数据的共享特征，识别待诊断目标设备的不同故障数据，利用源域交叉熵分类损失函数$L_S(\boldsymbol{X}_S,\boldsymbol{Y}_S)$度量诊断模型对已知类型数据分类的损失大小，利用目标域二分类损失函数$L_T(\boldsymbol{X}_T)$度量诊断模型将样本$\boldsymbol{X}_T$判为未知类型而可能产生的分类损失大小，通过最小化已知类型和未知类型数据的联合分类损失训练诊断模型，实现故障诊断。因此，总的模型训练损失函数可表示为

$$L=L_S(\boldsymbol{X}_S,\boldsymbol{Y}_S)+L_T(\boldsymbol{X}_T) \tag{5}$$

在训练过程中，采用小批量样本训练方法，利用源领域已知的数据样本$\{\boldsymbol{x}_s,\boldsymbol{y}_s\}$，$\{\boldsymbol{x}_t\}$训练特征提取模型和分类模型，计算损失函数更新模型的权重参数，最小化损失函数，使其能够正确区分已知的k种数据类型并识别第k+1种未知数据类型。模型权重更新策略如算法1所示。

算法1 基于J-CNN的开放集跨工况迁移故障诊断小批量样本训练算法。

For $i \leftarrow 1$ to epochs do

源领域小批量样本数据$\{\boldsymbol{x}_s,\boldsymbol{y}_s\}$

目标领域小批量样本数据$\{\boldsymbol{x}_t\}$

计算损失函数$L_S(\boldsymbol{X}_S,\boldsymbol{Y}_S)$，$L_T(\boldsymbol{X}_T)$

更新网络权重$\min\limits_{\boldsymbol{F}}$，$\min\limits_{\boldsymbol{C}}$

End

基于上述算法，搭建基于J-CNN的开放集跨工况迁移故障诊断模型，模型结构如图3所示。特征提取模型$\boldsymbol{F}$包括二维卷积层(Conv2D)和全连接层(Dense)，从不同领域的原始数据中提取可迁移的共享特征向量；特征分类模型$\boldsymbol{C}$包括全连接层和

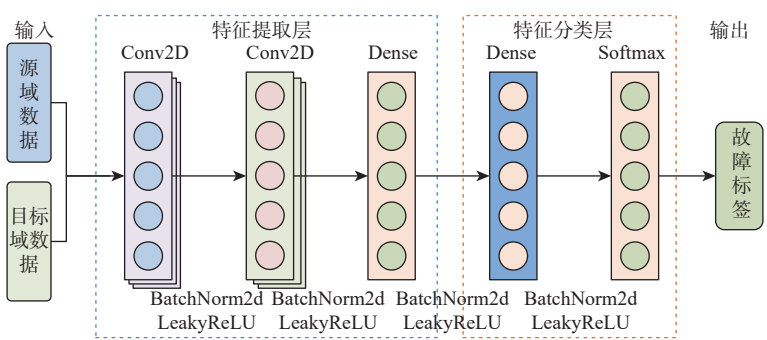


图3 基于J-CNN的开放集跨工况迁移故障诊断模型结构示意图

Fig. 3 Schematic structure of open-set cross-condition migration fault diagnosis model based on J-CNN

Softmax 层; BatchNorm2d 表示对中间层的输出向量进行归一化, 能够避免因数据分布不同导致的训练网络不稳定问题; LeakyReLU 表示非饱和激活函数, 能解决深度神经网络的“梯度消失”问题, 加快模型收敛速度。利用卷积层的非线性特征提取能力构建特征提取层, 通过 Softmax 函数对特征的故障类型进行识别。

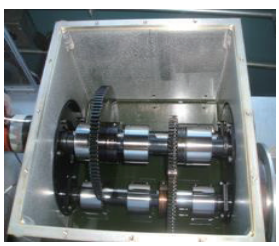
3　案例分析

为验证本文提出的基于 J-CNN 的开放集跨工况迁移故障诊断方法的有效性, 使用 2009 年 PHM 数据挑战赛发布的工业齿轮箱数据集进行案例验证。该齿轮箱数据集采集自一个工业用二级减速齿轮箱, 在齿轮箱输入端布置有加速度传感器, 用于采集齿轮箱振动数据信号, 如图 4 (a) 所示。该减速齿轮箱内部组成结构如图 4 (b)、(c) 所示, 输入轴齿轮的齿数为 32, 中间轴齿轮的齿数为 48, 一级减速比为 1.5, 输出轴齿轮的齿数为 80, 二级减速比为 1.667。

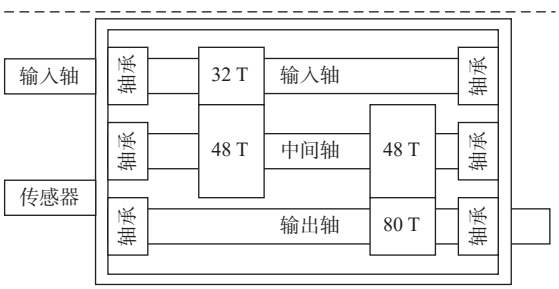
试验过程中, 对齿轮箱注入 4 种故障, 其详细故障信息如表 1 所示。输入轴具有 35, 40, 45, 50 Hz 4 种不同转速工况, 在每种工况下分别采集振动数据, 采样频率为 66.67 kHz, 采样时间为 4 s。



(a) 输入端加速度传感器的位置



(b) 齿轮箱内部结构



(c) 齿轮箱组成结构

图 4　二级减速齿轮箱组成结构

Fig. 4　Composition of secondary reduction gearbox

3.1　数据预处理及模型参数设置

利用提出的基于 J-CNN 的开放集跨工况迁移诊断模型, 借助源领域的辅助数据对目标数据集中的齿轮箱故障模式进行诊断。对每种故障模式下采集到的原始振动信号进行样本划分, 每个样本包括 4 000 个数据点。训练数据为源域工况的样本数据, 样本容量为 150, 每种故障模式有 50 组样本; 测试数据为目标域数据集, 样本容量为 80, 每种故障模式有 20 组样本。在训练过程中, 将训练的批次大小设置为 60, 训练迭代次数设置为 50 次, 损失函数设置为多类别交叉熵, 采用随机梯度下降 (stochastic gradient descent, SGD) 优化器, 初始学习率设置为 0.001, 学习率衰减设置为 1%。利用卷积神经网络特征自学习能力提取原始振动信号的故障特征, 在不同数据条件下训练故障诊断模型, 对测试样本进行故障诊断。

表 1　减速齿轮箱不同故障模式注入情况对比

Table 1　Comparison of different failure mode injections in reduction gearboxes

齿轮箱部件	故障模式	是否正常	故障1	故障2	故障3
齿轮	32T	正常	裂纹	正常	正常
	96T	正常	正常	正常	正常
	48T	正常	偏心	偏心	正常
	80T	正常	正常	断齿	正常
轴	输入	正常	正常	正常	不平衡
	输出	正常	正常	正常	正常
轴承	轴承1	正常	正常	滚动体	正常
	轴承2	正常	正常	正常	滚动体
	轴承3	正常	正常	正常	外圈
	轴承4	正常	正常	正常	正常
	轴承5	正常	正常	正常	正常
	轴承6	正常	正常	正常	正常

3.2　齿轮箱故障诊断结果

本节利用基于 J-CNN 的开放集跨工况迁移诊断方法, 通过减速齿轮箱数据集振动信号进行故障诊断。选取 35 Hz 转速作为源域工况, 40, 45, 50 Hz 转速作为不同的目标域工况。以 35～40 Hz 工况下的联合迁移诊断任务为例, 35～40 Hz 表示源域工况为 35 Hz, 目标域工况为 40 Hz, 源领域数据集为 35 Hz 转速下正常、故障 1、故障 2 等 3 种故障模式的数据, 目标领域数据集为 40 Hz 转速下正常、故障 1、故障 2 和未知故障等 4 种类型的齿轮箱数据, 其中, 源域数据集中缺少未知故障数据类型的训练样本。

为验证提出的开放集场景的基于 J-CNN 的开放集跨工况迁移诊断方法相对于传统基于迁移学习的跨工况故障诊断方法的性能, 本节将诊断结果与其他 3 种不同故障诊断模型进行了对比分析, 分别为 CNN 模型 (不使用联合迁移方法)、支持向量机 (support vector machine, SVM) 模型、概率神经网络 (probabilistic neural networks, PNN) 模型。故障诊断准确度如图 5 所示。

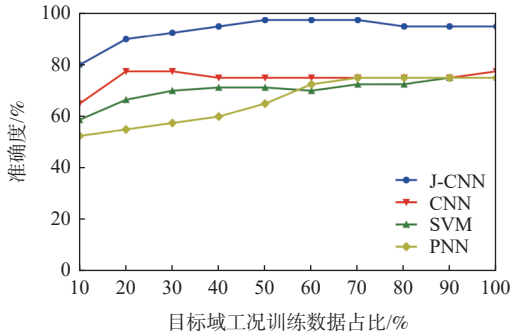


图5 35～40 Hz不同目标域工况数据占比诊断结果

Fig. 5 Diagnostic results of percentage of working condition data in different target domains from 35 Hz to 40 Hz

通过故障诊断准确度对比分析可以发现，本文提出的基于J-CNN的开放集跨工况迁移故障诊断方法在不同目标域工况数据条件下，均取得了最高的故障诊断准确度。当训练样本中目标工况样本量占比较小时，即使源域数据中缺少未知类型的训练样本，该方法也能够将35 Hz工况下的数据迁移到40 Hz工况数据的故障诊断任务中，取得了80%的诊断准确度；随着目标域工况数据占比逐渐增大，训练集中40 Hz工况的样本逐渐增多，源域和目标域的数据相似度逐渐增大，模型的诊断准确度也随之提高；当训练样本中目标工况样本量占比为100%时，虽然源域数据中缺少未知类型的训练样本，但J-CNN方法通过识别共享特征，能够判别未知的数据类型，故障诊断准确度达到了95%。

在对比方法中，CNN模型采用联合迁移方法相同的卷积神经网络结构，但未引入领域自适应策略，由于无法识别共享特征，缺乏对未知数据类型的判别能力，其平均诊断准确度为73.64%，低于J-CNN方法；SVM是常见的浅层机器学习分类模型，PNN是一种基于贝叶斯策略前馈神经网络，二者常用于封闭集数据的故障诊断任务，但在本文研究的开放集数据条件下，传统方法无法判别目标领域中包含未知的数据类型，因而对于开放集数据的故障诊断效果不佳。

文献[14]同样采用2009年PHM数据挑战赛工业齿轮箱数据集进行案例验证，为验证本文提出的考虑开放集场景的基于迁移学习的跨工况故障诊断方法相较于已有考虑开放集场景的跨工况故障诊断方法的性能，将本文诊断结果与文献[14]提出的基于DANN的开放集域自适应网络诊断结果进行对比分析。文献[14]的任务设置及诊断结果如表2所示。

现有的基于DANN的开放集故障诊断方法在源域相对目标域缺失故障模式数为1时的诊断准确度为89.51%与73.04%，本文提出的基于J-CNN的开放集跨工况迁移故障诊断方法在源域缺失故障模式数为1时，随着目标工况占比的变化，诊断准确度最高可达到97.5%。

表2 基于DANN的开放集故障诊断任务设置及诊断结果

Table 2 DANN-based open-set fault diagnosis task setup and diagnostic results

任务	跨工况情况	源域故障模式数	目标域故障模式数	准确度/%
P1	30～35 Hz	5	6	89.51
P2		4		85.64
P3		3		89.64
P4		2		78.85
P5		1		76.25
P6	35～30 Hz	5	6	73.04
P7		4		72.16
P8		3		83.57
P9		2		80.15
P10		1		81.93

4 结 论

1）基于J-CNN的开放集跨工况迁移故障诊断方法在不同目标域工况数据条件下，相较其他3种不考虑开放集场景的跨工况故障诊断方法，均取得了更高的故障诊断准确度。

2）当训练样本中目标工况样本量较小时，本文方法仍能有效地利用带故障标签的源工况数据对无标签的目标工况数据进行分类与标记。

3）通过识别共享特征，J-CNN方法能够判别未知的数据类型，实现了开放集场景下目标工况数据的故障诊断。

4）本文提出的基于J-CNN的开放集跨工况迁移故障诊断方法，相较基于DANN的开放集域自适应网络诊断方法，在源域缺失故障模式数均为1的条件下，在不同目标工况占比的情况下均取得了更高的故障诊断准确度，诊断准确度最高可达到97.5%，具有良好的分类准确度。

基于现有技术和结论，开放集场景下的跨工况故障诊断方法有以下可能的研究方向：

1）探索更先进的领域自适应方法，以提高模型在开放集数据条件下的性能。可以使用对抗性训练或其他领域自适应技术来增强模型的泛化能力。

2）在开放集跨工况故障诊断中，目标工况样本量可能较少。研究如何处理不平衡样本问题，以提高对目标工况的诊断准确度。

3）考虑将其他传感器数据（如温度、压力等）与齿轮箱数据集进行融合，以提高故障诊断的准确性。

4) 方法应用中考虑实际噪声、不确定性和其他现实因素的影响。

上述研究方向能够进一步拓展基于迁移学习的开放集跨工况故障诊断方法, 以更好地适应实际工程应用场景。

参考文献（References）

[1] SIAHPOUR S, LI X, LEE J. Deep learning-based cross-sensor domain adaptation for fault diagnosis of electro-mechanical actuators[J]. International Journal of Dynamics and Control, 2020, 8: 1054-1062.

[2] MOSLEM A, JASKARAN S, LI X, et al. Cross-domain gearbox diagnostics under variable working conditions with deep convolutional transfer learning[J]. Journal of Vibration and Control, 2020, 27(7-8): 854-864.

[3] ZHANG W, LI X, MA H, et al. Open set domain adaptation in machinery fault diagnostics using instance-level weighted adversarial learning[J]. IEEE Transactions on Industrial Informatics, 2021, 17(11): 7445-7455.

[4] 陈宏, 邓芳明, 吴翔, 等. 基于梯度提升决策树的电力电子电路故障诊断[J]. 测控技术, 2017, 36(5): 9-12.
CHEN H, DENG F M, WU X, et al. Fault diagnosis of power electronics circuit based on gradient boosting decision tree[J]. Measurement & Control Technology, 2017, 36(5): 9-12(in Chinese).

[5] 王廷轩, 刘韬, 王振亚, 等. 融合迁移卷积神经网络的跨域滚动轴承故障诊断[J]. 电子测量技术, 2021, 44(10): 167-174.
WANG T X, LIU T, WANG Z Y, et al. Cross-domain rolling bearing fault diagnosis based on convolutional neural network combined with transfer learning[J]. Electronic Measurement Technology, 2021, 44(10): 167-174(in Chinese).

[6] 洪晓翠, 段礼祥, 杨晓光, 等. 智能优化算法在机械故障诊断领域的应用综述[J]. 测控技术, 2021, 40(7): 1-8.
HONG X C, DUAN L X, YANG X G, et al. Review on the application of intelligent optimization algorithms in mechanical fault diagnosis[J]. Measurement & Control Technology, 2021, 40(7): 1-8(in Chinese).

[7] 张根保, 李浩, 冉琰, 等. 一种用于轴承故障诊断的迁移学习模型[J]. 吉林大学学报 (工学版), 2020, 50(5): 1617-1626.
ZHANG G B, LI H, RAN Y, et al. A transfer learning model for bearing fault diagnosis[J]. Journal of Jilin University (Engineering and Technology Edition), 2020, 50(5): 1617-1626(in Chinese).

[8] 刘应东, 刘韬, 李华, 等. 变工况轴承的联合分布适应迁移故障诊断[J]. 电子测量与仪器学报, 2021, 35(5): 69-75.
LIU Y D, LIU T, LI H, et al. Transfer fault diagnosis of bearings under variable working conditions based on joint distribution adaptation[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(5): 69-75(in Chinese).

[9] 毕爽. 基于深度迁移学习的风电机组齿轮箱故障诊断方法研究[D]. 长春: 长春大学, 2021.
BI S. Research on fault diagnosis method of wind turbine gearbox based on deep transfer learning[D]. Changchun: Changchun University, 2021(in Chinese).

[10] 陈仁祥, 杨星, 胡小林, 等. 深度置信网络迁移学习的行星齿轮箱故障诊断方法[J]. 振动与冲击, 2021, 40(1): 127-133.
CHEN R X, YANG X, HU X L, et al. Planetary gearbox fault diagnosis method based on deep belief network transfer learning[J]. Journal of Vibration and Shock, 2021, 40(1): 127-133(in Chinese).

[11] CAO P, ZHANG S L, TANG J. Preprocessing-free gear fault diagnosis using small datasets with deep convolutional neural network-based transfer learning[J]. IEEE Access, 2018, 6: 26241-26253.

[12] MA P, ZHANG H L, FAN W H, et al. A novel bearing fault diagnosis method based on 2D image representation and transfer learning-convolutional neural network[J]. Measurement Science and Technology, 2019, 30: 055402.

[13] CHEN Z Y, HE G L, LI J P, et al. Domain adversarial transfer network for cross-domain fault diagnosis of rotary machinery[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8702-8712.

[14] ZHAO C, SHEN W M. Dual adversarial network for cross-domain open set fault diagnosis[J]. Reliability Engineering & System Safety, 2022, 221: 108358.

[15] 文成林, 吕菲亚. 基于深度学习的故障诊断方法综述[J]. 电子与信息学报, 2020, 42(1): 234-248.
WEN C L, LV F Y. Review on deep learning based fault diagnosis[J]. Journal of Electronics & Information Technology, 2020, 42(1): 234-248(in Chinese).

[16] CHEN W Q, QIU Y N, FENG Y H, et al. Diagnosis of wind turbine faults with transfer learning algorithms[J]. Renewable Energy, 2021, 163: 2053-2067.

[17] PENG C, LI L L, CHEN Q, et al. A fault diagnosis method for rolling bearings based on parameter transfer learning under imbalance data sets[J]. Energies, 2021, 14(4): 1-18.

[18] BUSTO P P, GALL J. Open set domain adaptation[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway: IEEE Press, 2017: 754-763.

[19] LI X, ZHANG W, DING Q, et al. Intelligent rotating machinery fault diagnosis based on deep learning using data augmentation[J]. Journal of Intelligent Manufacturing, 2020, 31(2): 433-452.

[20] TANG S N, YUAN S Q, ZHU Y. Deep learning-based intelligent fault diagnosis methods toward rotating machinery[J]. IEEE Access, 2020, 8: 9335-9346.

[21] LI F, TANG T J, TANG B P, et al. Deep convolution domain-adversarial transfer learning for fault diagnosis of rolling bearings[J]. Measurement, 2021, 169: 108339.

[22] 郭瑜, 童丽娜, 倪旭明. 基于改进卷积神经网络的电力通信网故障诊断研究[J]. 计算机测量与控制, 2022, 30(2): 24-30.
GUO Y, TONG L N, YAN X M. Research on fault diagnosis of electric power communication network based on improved convolutional neural network[J]. Computer Measurement & Control, 2022, 30(2): 24-30(in Chinese).

Fault diagnosis of gearbox under open set and cross working condition based on transfer learning

MA Xiang[1, 2], XU Shu[1, 2], SHANG Pengchao[1], MA Jian[1, 2, 3, 4, *], ZHOU Ruzhi[5]

(1. School of Reliability and Systems Engineering, Beihang University, Beijing 100191, China;
2. Key Laboratory of Reliability and Environmental Engineering Technology, Beihang University, Beijing 100191, China;
3. Institute of Reliability Engineering, Beihang University, Beijing 100191, China;
4. International Innovation Institute, Beihang University, Hangzhou 311115, China;
5. Shanghai Institute of Satellite Engineering, Shanghai 201109, China)

Abstract: With the continuous development of industry and aerospace technology, the working conditions and failure modes of rotating machinery are becoming increasingly diversified and complex, and reliability and safety problems are becoming increasingly prominent. It is critical to research efficient fault detection techniques since many working condition data lack fault labels and the failure modes amongst various working conditions are asymmetric. Take the gearbox as the case verification object, set up cross-working conditions, and open set fault diagnosis scenarios. A method is proposed to address the issue of lacking fault labels under the target working condition. It takes into account the ability of migration learning to facilitate cross-domain knowledge application. Specifically, migration learning is used to transfer knowledge from the source working condition to the target working condition, and the cross entropy classification loss function is used to identify known fault types. However, transfer learning has the problem that the greater the field difference is, the worse the effect is. It is difficult to solve the open set problem of asymmetric fault modes under cross-working conditions. In order to identify the known and unknown classes of target working circumstances, a method utilizing a convolutional neural network to extract similar data characteristics between working conditions is proposed. The two classification loss functions are then used in this process. The joint loss function is proposed to train the diagnosis model and realize the joint migration of fault features from the source domain to the target domain. The results of the case analysis show that the method can realize cross-working condition fault diagnosis under an open set, and the average diagnostic accuracy is more than 90%.

Keywords: rotating machinery; data-driven; open set; transfer learning; fault diagnosis

Received: 2022-08-17; **Accepted**: 2022-09-23; **Published Online**: 2022-12-28 12:13

URL: link.cnki.net/urlid/11.2625.V.20221227.1135.001

Foundation items: The Fundamental Research Funds for the Central Universities (YWF-22-L-516); Special Research on Civil Aircraft (MJ-2018-Y-58)

* **Corresponding author**. E-mail: 09977@buaa.edu.cn