

DOI: 10.19650/j.cnki.cjsi.J2007241

# 深度嵌入关系空间下齿轮箱标记样本扩充 及其半监督故障诊断方法\*

吕枫<sup>1</sup>, 王义<sup>1,2</sup>, 阮胡林<sup>1</sup>, 秦毅<sup>1,2</sup>, 王平<sup>3</sup>

(1. 重庆大学机械工程学院 重庆 400044; 2. 重庆大学机械传动国家重点实验室 重庆 400044;  
3. 中国航发湖南动力机械研究所 株洲 412002)

**摘要:**针对只有少量标记样本的情况下,传统的基于深度学习的齿轮箱故障诊断方法训练出来的深度模型泛化能力差并且容易发生过拟合的问题,提出了一种基于深度嵌入关系空间下齿轮箱标记样本扩充的齿轮箱半监督故障诊断方法。该方法将少量的有标记振动信号以成对的输入方式输入到关系网络中进行监督训练,然后以有标记振动信号为参考,将大量的无标记振动信号输入到训练好的关系网络中,建立有标记信号与无标记信号的嵌入关系空间。在关系空间中将具有最大相似的无标记信号被挑选出,并赋予其预测标记作为伪标签添加到有标记振动信号集中,重复上述步骤以进行有标记样本集扩充,以提高关系网络的泛化能力,当关系网络训练好后用于机械故障诊断,实现故障的诊断及分类。实验结果表明:利用本诊断方法处理只有少量标记样本的齿轮振动信号时,成功地实现了少量标记样本的扩充,并取得了优于传统的监督和半监督故障诊断方法的齿轮箱故障辨识效果。

**关键词:** 关系网络; 半监督学习; 齿轮箱故障诊断; 伪标签学习

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

## Labeled sample augmentation based on deep embedding relation space for semi-supervised fault diagnosis of gearbox

Lyu Feng<sup>1</sup>, Wang Yi<sup>1,2</sup>, Ruan Hulin<sup>1</sup>, Qin Yi<sup>1,2</sup>, Wang Ping<sup>3</sup>

(1. College of Mechanical Engineering, Chongqing University, Chongqing 400044, China;  
2. State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China;  
3. AECC Hunan Aviation Powerplant Research Institute, Zhuzhou 412002, China)

**Abstract:** In the case of a small amount of labeled sample data, the deep model trained by the traditional deep learning-based gearbox fault diagnosis method has poor generalization ability, which is prone to over-fitting. To address this issue, a semi-supervised fault diagnosis method for the gearbox is proposed, which is based on the augmentation of labeled sample in deep embedding relation space. In this method, a small number of labeled vibration signals are input into the relation network in pairs for supervised training. Then, the labeled vibration signals are used as references, and a large number of unlabeled vibration signals are input into the trained relation network to establish the embedding relation space between labeled signals and unlabeled signals. In the relation space, some of the most similar signals are selected, and their predicted labels are set as pseudo labels and added to the labeled vibration signals. The above steps are iterated to expand the labeled samples to improve the generalization ability of the relation network. After the relation network is trained, it is used for mechanical fault diagnosis to realize fault diagnosis and classification. Experimental results show that the proposed method successfully expands the number of labeled sample when it is used to process the gear vibration signals with only a small number of labeled samples. The gearbox fault identification effect is better than the traditional supervised and semi-supervised fault diagnosis methods.

**Keywords:** relation network; semi-supervised learning; gearbox fault diagnosis; pseudo label learning

收稿日期: 2020-12-15      Received Date: 2020-12-15

\* 基金项目: 国家自然科学基金(51805050)资助、西安交通大学机械制造系统工程国家重点实验室开放课题(sklms2020014)项目资助

## 0 引言

随着装备制造业的迅速发展,旋转机械被广泛运用于各类工业场合,如航空航天、风力发电、高速列车、清洁能源等。齿轮箱用于传递动力和调整传动比是旋转机械设备中最关键的核心部件<sup>[1]</sup>。然而,在实际的工业场合中,旋转机械因为工作环境恶劣以及疲劳磨损等不利因素,齿轮箱部件面临较高的故障风险。而故障一旦发生将会对整个机械设备安全稳定地运行产生严重影响,如:设备意外停机造成严重的经济损失甚至巨大的安全威胁<sup>[2]</sup>。根据相关统计,旋转机械设备中80%的故障是由齿轮引发的,其中齿轮箱中的齿轮故障又占60%<sup>[3]</sup>。因此,对运行中的齿轮箱部件进行实时的状态监测和故障诊断,以便及时发现齿轮箱的早期故障,对旋转机械设备的健康管理和风险预警具有重要意义。

目前,针对齿轮箱的故障诊断,主要集中于特征提取方法的研究,通过提取的特征反应齿轮的故障模式,实现故障模式的识别和分类。随着深度学习技术的蓬勃发展,很多专家学者利用机器学习算法进行机械故障的诊断分类,例如:支持向量机(support vector machines, SVM)<sup>[4]</sup>、随机森林(random forest, RF)<sup>[5]</sup>以及人工神经网络(artificial neural networks, ANN)<sup>[6]</sup>等方法。这些方法往往需要对采集到的故障振动的信号进行特征提取,然后利用相关模式判别模型进行故障诊断。随着相关研究的进一步推进,基于传统机器学习的机械故障诊断方法已经取得了一些优秀的成果。然而,此类方法需要提取到与故障信息相关的敏感性特征,使得该类方法极度的依赖于专家经验和先验知识<sup>[7]</sup>。由此,上述缺点严重的限制了传统机器学习故障模式识别方法在实际工业场合中的应用和部署。

近年来,随着人工智能技术的发展,深度学习已经成为了各界的研究热点<sup>[8]</sup>。深度学习方法进行故障诊断时无需额外的特征工程,即可同时实现特征提取和模式识别,避免了依赖专家经验和先验知识<sup>[9]</sup>。其中,以卷积神经网络(convolutional neural network, CNN)为代表的深度学习的算法,因其具有良好的特征提取能力以及建模能力被广泛应用于图像分类<sup>[10]</sup>、语音识别<sup>[11]</sup>等领域,并取得了很好的成果。同时,得益于其强大的特征能力和非线性建模能力,很多学者将其运用到旋转机械故障诊断领域<sup>[12-15]</sup>。胡葛庆等<sup>[16]</sup>利用经验模态分解对振动信号进行处理,然后利用DCNN进行提取特征,最后将特征运用于分类器进行分类识别,实现对齿轮箱故障的诊断。Wang等<sup>[17]</sup>将轴承振动信号生成为不同健康状态下的二维灰度图像,并将其分为测试集和训练集对CNN模型进行训练,以准确地实现轴承故障诊断。宫文峰等<sup>[18]</sup>采用

了一种改进CNN结合支持向量机的方法对电机轴承微小故障进行快速智能诊断。以上基于深度学习的方法能够获得很好的特征学习能力以及非线性拟合能力。

但是对于构造良好的深度学习模型,往往需要大量的有标记信号进行模型训练,上述条件在实际工作场所很难满足<sup>[19]</sup>。基于此,Shahani等<sup>[20]</sup>提出了半监督学习方法,该方法能够利用部分已标记的样本和足够的未标记本来训练识别模型。基于这种方法,Zhang等<sup>[21]</sup>采用了一种半监督框架进行行星齿轮箱的故障分类。Yu等<sup>[22]</sup>提出了一种数据扩充和度量学习的半监督学习方法用于轴承故障诊断监测。Wang等<sup>[23]</sup>提出了一种半监督映射流形学习算法对风电机组的滚动轴承进行故障识别和诊断。张鑫等<sup>[24]</sup>提出了一种基于拉普拉斯特征映射和深度置信网络的半监督故障识别模型,对机械设备的故障模式进行识别。如何构建一种深度模式识别方法以解决少量标记样本所带来的模型过拟合问题和弱泛化能力问题,对实际工业中的齿轮箱故障诊断具有重要意义。

在现有的研究基础上,本文受到关系网络<sup>[25]</sup>和伪标签学习<sup>[26]</sup>的启发,提出了一种基于深度嵌入关系空间伪标签学习标记样本扩充的齿轮箱半监督故障诊断方法。该方法利用关系网络构建一个强大的嵌入关系空间,使得在该空间下可以有效的度量已标记样本和未标记样本之间的相似性。然后引入一种新颖的伪标签学习方法用于选择和标记在构造的嵌入关系空间中与标记样本具有极大相似的未标记样本,并将所选择的样本视为标记样本,并用于重新训练关系网络。通过循环上述步骤,以渐进方式实现齿轮箱故障样本扩充和深度关系模型泛化能力提升。最终将训练好的关系网络用于实现齿轮故障的诊断及分类。利用齿轮箱实验将该方法与其他几类故障诊断方法进行了对比分析,结果显示本文所提出的故障诊断方法性能优于其他几类诊断方法,诊断结果准确率更高且稳定性更好。

## 1 关系网络与伪标签学习

### 1.1 关系网络

关系网络是针对少量训练样本可用的情况下进行模式识别而开发的,与传统的基于大量标记信号训练的深度学习网络不同,该网络能减少对标记样本的需求并能达到较高的故障识别精度。

关系网络包含两个模块,即特征提取模块,和关系模块。特征提取模块从原始输入的振动信号中提取特征,而关系模块用来辨识样本之间的关联性。特征提取模块由4个卷积层和2个池化层组成,前两个卷积层采用了宽核,目的是从原始输入信号中提取全局特征,并在池化

层之后进行卷积,以消除冗余表示。关系模块包含两个卷积层,两个池化层和两个完全连接层,与特征提取模块不同,关系模块中每个卷积层中使用窄核,从输入特征图中获取局部信息。最后引入神经元数为8和1的全连接层,以得到成对输入样本之间的关系评分。这两个模块都包含一系列深度学习层,如卷积层、池化层、批归一化层、全连接层。两个模块结构如图1所示。

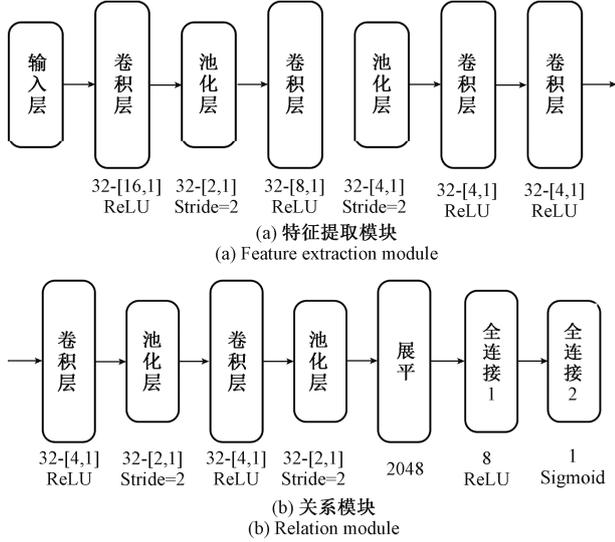


图1 关系网络模块结构

Fig. 1 Structure of the relation network module

在关系网络中,  $D_l = \{(x_i^i, y_i^i)\}_{i=1}^m$  和  $D_{un} = \{x_{un}^j\}_{j=1}^n$  分别代表标记样本集和未标记样本集,在训练中,样本  $x_i^i$  和  $x_i^j$  从标记样本集中随机抽取,作为配对的输入样本,输入到特征提取模块中。配对输入样本生成的特征图表示为:

$$F_l^i = G_e(x_i^i; \theta_e) \quad (1)$$

$$F_l^j = G_e(x_i^j; \theta_e) \quad (2)$$

式中:  $F_l^i$  和  $F_l^j$  为样本  $x_i^i$  和  $x_i^j$  的特征图;  $G_e(\cdot; \cdot)$  为特征提取模块;  $\theta_e$  为相应的参数。

然后通过连接操作  $C(\cdot; \cdot)$  将生成的特征图组合起来,数学计算公式为:

$$F_{con}^{ij} = C(F_l^i; F_l^j) \quad (3)$$

式中:  $F_{con}^{ij}$  表示通过连接操作耦合特征映射。

将耦合的特征图输入到关系模块中,得到一个范围为  $[0, 1]$  的关系值  $r_{ij}$ ,其表示两个输入样本之间的关系或相似度。计算关系评分  $r_{ij}$  用下式表示:

$$r_{ij} = G_r(F_{con}^{ij}; \theta_r) \quad (4)$$

式中:  $G_r(\cdot; \cdot)$  为关系模块,  $\theta_r$  为对应的参数。

训练深度模型,利用均方误差损失函数来评估真实得分  $r_{ij}^{truth}$  与预测关系评分  $r_{ij}$  之间的差异。假设实际分数等于1即配对输入样本来自同一类别(即高度相似),若

为0即配对输入样本极其不同。模型优化的数学表达式为:

$$\hat{\theta}_e, \hat{\theta}_r \leftarrow \operatorname{argmin}_{\theta_e, \theta_r} \frac{1}{m \times m} \sum_{i=1}^m \sum_{j=1}^m (r_{ij} - r_{ij}^{truth})^2 \quad (5)$$

$$r_{ij}^{truth} = 1(y_i^i = y_i^j) \quad (6)$$

式中:  $1(\cdot)$  为指标函数。

在测试阶段,分别将标记样本(标记样本集每个类别一个样本)和未标记样本(未标记样本集一个样本)送入关系网络。根据得到的关系得分,对未标记样本的预测类别进行识别。

## 1.2 伪标签学习

伪标签技术是一种半监督学习策略,能够同时利用有标记样本和无标记样本。在伪标签学习中,利用有限的有标记样本以监督方式训练一个深度模型,同时通过正向传播得到无标记样本的伪标签,这些伪标签也用于辅助深度网络进行训练。

在全连接神经网络中有  $M$  个隐藏层,隐藏层的输出特征可以用下式表示:

$$h^m = \sigma(W^m h^{m-1} + b^m), m = 1, \dots, M+1 \quad (7)$$

式中:  $h^{m-1}$  为第  $M-1$  隐藏层的输出特征;  $W^m$  和  $b^m$  为层  $M$  的相关系数。  $\sigma(\cdot)$  为激活函数。

通过监督交叉熵损失对深度神经网络进行训练

$$\hat{\theta}_{w,b} \leftarrow \operatorname{argmin}_{\theta_{w,b}} \frac{1}{m} \sum_{i=1}^m L(f(x_i^i; \theta_{w,b}), y_i^i) \quad (8)$$

式中:  $f(\cdot; \theta_{w,b})$  为深度神经网络模型;  $\theta_{w,b}$  为模型参数;  $L(\cdot)$  为交叉熵损失函数;  $\{x_i^i, y_i^i\}$  为标记样本。

在伪标签学习中,同时使用有标记的样本和无标记的样本训练深度网络模型。对于未标记样本  $x_{un}^j$ ,通过正向传播得到预测概率最大的一类作为对应的伪标签  $\hat{y}_{un}^j$ ,即:

$$\hat{y}_{un}^j = O(\operatorname{argmax}_{k \in \{0, \dots, K-1\}} (f_k(x_{un}^j; \theta_{w,b}))) \quad (9)$$

式中:  $O(\cdot)$  为独热编码操作。

结合标记样本和未标记样本的修正交叉熵损失函数为:

$$\hat{\theta}_{w,b} \leftarrow \operatorname{argmin}_{\theta_{w,b}} \left\{ \frac{1}{m} \sum_{i=1}^m L(f(x_i^i; \theta_{w,b}), y_i^i) + \alpha(t) \frac{1}{n} \sum_{j=1}^n L(f(x_{un}^j; \theta_{w,b}), \hat{y}_{un}^j) \right\} \quad (10)$$

式中:  $\alpha(t)$  为平衡监督交叉熵损失和非监督交叉熵损失的系数。

## 1.3 基于关系网络的样本扩充

关系网络用于在只有少量标记样本的情况下利用标记样本与未标记样本之间的关系或相似性,对标记样本集进行扩充。

已知标记样本集  $D_l = \{(x_i^i, y_i^i)\}_{i=1}^m$  和未标记样本集

$D_{un} = \{x_{un}^j\}_{j=1}^n$ ,其中包含  $K$  种不同的故障类型。在训练阶段,通过构造成对的输入样本,可以生成  $m^2$  个学习任务,计算式如下:

$$T_l = \sum_{i=1}^m \sum_{j=1}^m \{ (x_i^i, x_j^j), 1(y_i^i == y_j^j) \} \quad (11)$$

式中:  $T_l$  为生成的学习任务;  $1(\cdot)$  为指标函数。

这种方法与添加噪声和生成对抗等传统的数据增强方法相比,关系网络不会改变原始振动信号的数据分布,避免了对深层模型造成额外的扰动。然后根据式(5),利用生成的学习任务,通过反向传播算法对关系网络进行优化训练,一旦模型训练好,关系网络就能够度量两个输入样本之间的关系或相似度。将标记样本和未标记样本送入关系网络,最终构造出两类样本的嵌入关系空间,如图2所示。

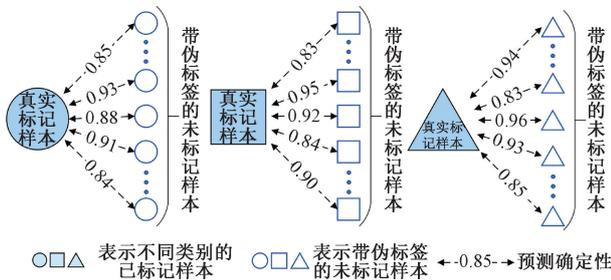


图2 嵌入关系空间

Fig. 2 Embedding relation space

在构造的嵌入关系空间中,每个未标记的样本上会附加两个元素,分别为预测标记和预测标记的确定性。未标记样本的伪标签为关系得分最大的类,可以表示为:

$$y_{pseudo}^j = O(\arg\max_{k \in \{0, \dots, K-1\}} (s_j[k])) \quad (12)$$

式中:  $y_{pseudo}^j$  为未标记样本  $x_{un}^j$  的预测伪标签;  $O(\cdot)$  为独热编码操作;  $s_j$  为未标记样本  $x_{un}^j$  的输出关系得分向量,计

算式为:

$$P_{cer}^j = \max(s_j) \quad (13)$$

式中:  $P_{cer}^j$  为未标记样本  $x_{un}^j$  的预测确定性,构造的嵌入关系空间描述了标记样本与未标记样本之间的联系。

并通过参考 K-近邻(K near neighbor, KNN)算法<sup>[27]</sup>,选择并标记具有最高  $n_s$  预测确定性的未标记样本,如图3所示。对于所选择的未标记样本,将相应的伪标签转换为真实标记,从而可以将其视为标记样本并添加到标记样本集中。进而扩展原始标记训练样本集,从而提高关系网络的泛化能力。

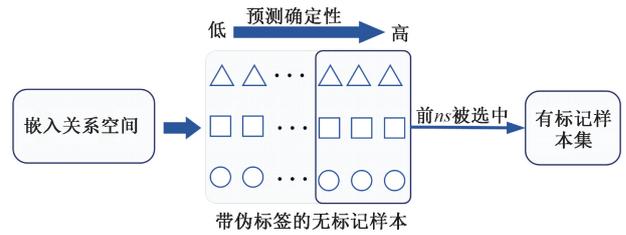


图3 标记样本扩充示意图

Fig. 3 Schematic diagram of the labeled sample augmentation

## 2 深度嵌入关系空间下齿轮箱标记样本扩充及其半监督故障诊断方法

为了解决在极少量标记样本可用的情况下仍能进行齿轮的故障诊断的问题,并能达到较高的准确率,本文提出了一种基于深度嵌入关系空间齿轮箱标记样本扩充及其半监督故障诊断方法。该方法在利用基于关系网络标记样本扩充进行半监督故障诊断时,分为以下几个步骤:振动信号采集与标准化、有标记振动信号样本集扩充、深度故障分类模型的建立以及齿轮箱实时运行状态监测和故障诊断。如图4所示。

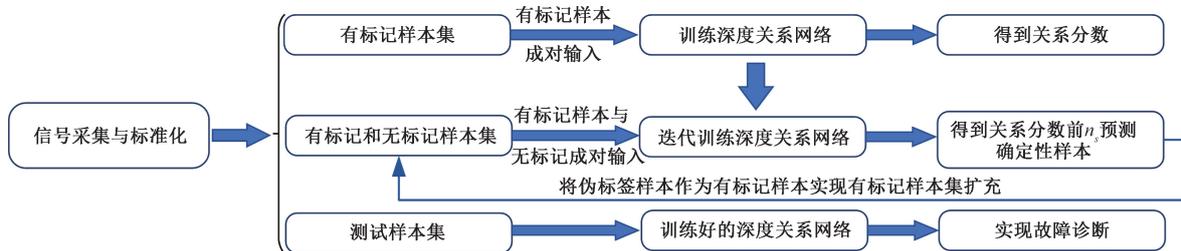


图4 基于关系网络标记样本扩充的半监督故障诊断方法

Fig. 4 The semi-supervised fault diagnosis method based on the labeled sample augmentation in relation network

### 1) 振动信号采集与标准化

采用振动加速度传感器测得到不同健康状态下齿轮箱部件的振动信号,对有标记信号集中的每个信号样本进行故障类别标注,然后对信号集进行数据标准化,以便

进行深度模型训练。

### 2) 有标记振动信号样本集扩充

从有标记信号集中随机选择两个振动信号并构成输入样本对,将生成的样本对输入到深度关系网络中进行

模型训练。一旦模型训练好之后,深度关系网络能定量衡量输入样本对之间的相似性。以建立的关系空间为参考,将具有前  $n_s$  个最大预测确定性的无标记信号选择出来,其预测标记被当作真实标记。选择出来的无标记样本结合其预测标记添加到有标记信号集中,实现标记样本扩充。

3) 深度故障分类模型的建立

将扩充后的有标记样本集用于深度关系网络的再训练。通过循环执行标记样本扩充和深度关系网络再训练逐步提高模型的泛化能力和模式分类能力。训练结束后保存模型参数,并用于齿轮故障诊断。

4) 齿轮箱实时运行状态监测和故障诊断

首先进行故障振动信号预处理,即对采集到的齿轮箱运行数据进行标准化预处理。将处理得到的运行数据输入到训练好的故障诊断模型中,进行齿轮箱故障模式识别和健康状态预测。

### 3 标记样本扩充的齿轮箱故障诊断实验验证及结果

#### 3.1 变速箱齿轮故障实验

本部分采用文献[28]的两级平行轴齿轮箱实验台进行故障诊断算法验证,齿轮箱实验台结构如图 5 所示。实验台主要由驱动电机、转速表、加速度表、两级并联变速齿轮箱和电磁制动器组成。其中驱动电机以开环方式控制齿轮的速度,电磁制动器可以通过改变其输入电压来提供不同的扭矩,齿轮箱的第一级输入轴包括一个 32 齿的小齿轮和一个 80 齿的齿轮,第二级输出轴包括一个 48 齿的小齿轮和一个 64 齿的齿轮。利用加速度计和转速计分别测量齿轮振动信号以及转轴的转速,采样频率为 20 kHz。实验模拟了 9 种不同的齿轮故障类型,其说明如表 1 所示,所有故障均位于安装在输入轴上的 32 齿小齿轮上。实验齿轮的故障类型包括健康状态、表面剥落、齿根裂纹、缺齿和齿顶磨损,其中,齿轮齿顶磨损可以进一步细分为 5 个不同的严重程度,如图 6 所示。

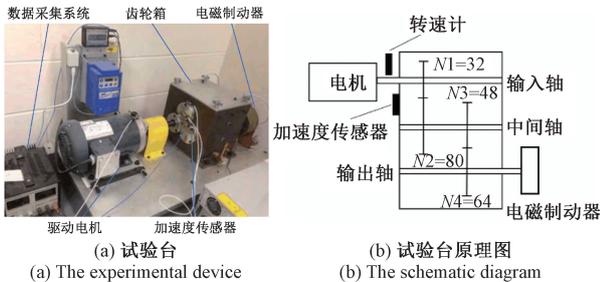


图 5 两级变速箱实验装置及其原理图<sup>[28]</sup>

Fig. 5 The two-stage gearbox experimental device and the schematic diagram<sup>[28]</sup>



图 6 不同健康状况的齿轮<sup>[28]</sup>

Fig. 6 The gears with different health conditions<sup>[28]</sup>

表 1 齿轮 9 种健康状态

Table 1 The nine health states of gears

状态	标记	故障描述
HS	0	健康
GSS	1	齿轮表面剥落
GRC	2	齿轮齿根裂纹
GMT	3	齿轮缺齿
GCT1	4	齿轮磨损 1(轻微故障)
GCT2	5	齿轮磨损 2
GCT3	6	齿轮磨损 3
GCT4	7	齿轮磨损 4
GCT5	8	齿轮磨损 5(严重故障)

#### 3.2 实验参数及故障诊断框架

根据第 1 节所述,深度关系网络包含两个模块以实现输入信号故障特征提取和样本间相似性计算。其中,特征提取模块包含 4 个卷积层和 2 个池化层,靠前的卷积层采用大尺寸的卷积核以增加局部感知范围实现输入信号全局特征信息提取,靠后的卷积层使用小尺寸卷积核以精准化聚焦输入特征实现输入特征图细节特征信息提取;池化层用于消除冗余特征以减少运算量和增加局部感受野。关系计算模块包含两个卷积层、两个池化层和两个全连接层。在卷积层中采用小尺寸卷积核以实现输入特征图的精细化特征表达,引入全连接层用于提取到的深度抽象特征的逻辑回归,实现输入信号样本的相似性衡量。此外,深度关系网络还包含特征组合模块,其具体为矩阵拼接运算,不包含待训练参数。由于关系网络具有深度架构,为避免模型难以训练的问题,在每个卷积层中均添加批量归一化操作以减少数据分布变化。同时,除最后一层全连接层,其余层均采用 ReLU 激活函数,以避免后向传播梯度消失问题。深度关系网络的参数设置如表 2 所示。

表2 深度关系网络模型结构和参数设置

Table 2 Structure and parameters setting of the deep relation network model

序号	神经网络层	核尺寸	核数量	步长	补零	输出规模
1	输入层	/	/	/	/	[2,1024, 1,1]
2	Conv + BN + ReLU	16 × 1	32	1 × 1	SAME	[2,1024, 1,32]
	池化	2 × 1	32	2 × 1	/	[2,512, 1,32]
	Conv + BN + ReLU	8 × 1	32	1 × 1	SAME	[2,512, 1,32]
	池化	2 × 1	32	2 × 1	/	[2,256, 1,32]
	Conv + BN + ReLU	4 × 1	32	1 × 1	SAME	[2,256, 1,32]
3	特征组合模块	特征组合	/	/	/	[1,256, 1,64]
	Conv + BN + ReLU	4 × 1	32	1 × 1	SAME	[1,256, 1,32]
	池化	2 × 1	32	2 × 1	/	[1,128, 1,32]
	Conv + BN + ReLU	4 × 1	32	1 × 1	SAME	[1,128,1,32]
	池化	2 × 1	32	2 × 1	/	[1,64,1,32]
4	展平	/	/	/	/	[1,2048]
	全连接+ReLU	8	1	/	/	[1,8]
	全连接+Sigmoid	1	1	/	/	[1,1]

为了验证所提出方法的有效性,实验引入多种智能故障诊断方法作为对比用于齿轮故障模式分类,用于对比的故障诊断方法如下所述:

1) 卷积神经网络,模型包含3层卷积、3层池化以及3层全连接;每层卷积层包含16个卷积核,卷积核尺寸分别为16、8、4;全连接层参数分别为512、256、9。2) 卷积神经网络+Dropout<sup>[29]</sup>,在传统卷积神经网络的基础上引入了Dropout方法以缓解模型过拟合问题,其中,Dropout率设置为0.2。3) 标签传播算法<sup>[30]</sup>,该方法是一种基于正则化图的半监督学习方法,采用径向高斯核,核系数设为0.25。4) 深度自编码器,网络结构为1024-512-256-128-9,使用未标记样本对自编码器模型进行预训练,采用少量有标记样本对分类器进行训练和微调。5) 孪生网络<sup>[31]</sup>,采用小样本学习策略,通过构建成对输入样本形式实现学习任务扩充,被成功的应用于轴承的智能故障诊断。6) PAR网络(position-aware relation networks, PARN)<sup>[32]</sup>,采用相关注意力机制以提取到与位置相关的细粒度特征,其模型结构和参数配置与关系网络相似。

如前所述,针对每类齿轮健康类型,分别得到250个训练样本和62个测试样本。在半监督故障诊断案例研究中,只有4%的训练样本被标记,其余的训练样本没有任何标记信息。模型相关超参数设置如表3所示。本文所提出的深度嵌入关系空间下齿轮故障诊断框架的结构如图7所示。

表3 框架超参数设置

Table 3 Hyper-parameters setting of the frame

阶段	参数	数值
嵌入关系空间	批量大小	45
	训练次数	1 000
	学习速率	0.001
	优化器	Adam
标记样本扩充	迭代次数	4
	选择的样本数量	[60,60,60,20]

### 3.3 实验结果及分析

#### 1) 半监督条件下齿轮故障诊断研究

为了消除随机因素引起的干扰,所有故障诊断实验重复多次,并采用其故障辨识准确率均值和标准差用于衡量每种方法的性能。此外,训练集中的未标记样本作为验证数据集,用以辅助评估每种方法的有效性。采用所提出方法和传统智能诊断方法得到的故障分类结果如表4所示。

如图8所示,相较于传统的智能故障诊断方法,所提出的半监督故障诊断方法具有较好的故障辨识性能。具体而言,在4%标记样本条件下,所提出方法能够以0.89%的标准差实现98.59%的分类准确率,说明所提出方法不仅具有优异的模式分类性能,而且具有良好的稳定性。相比于卷积神经网络和卷积神经网络+Dropout的

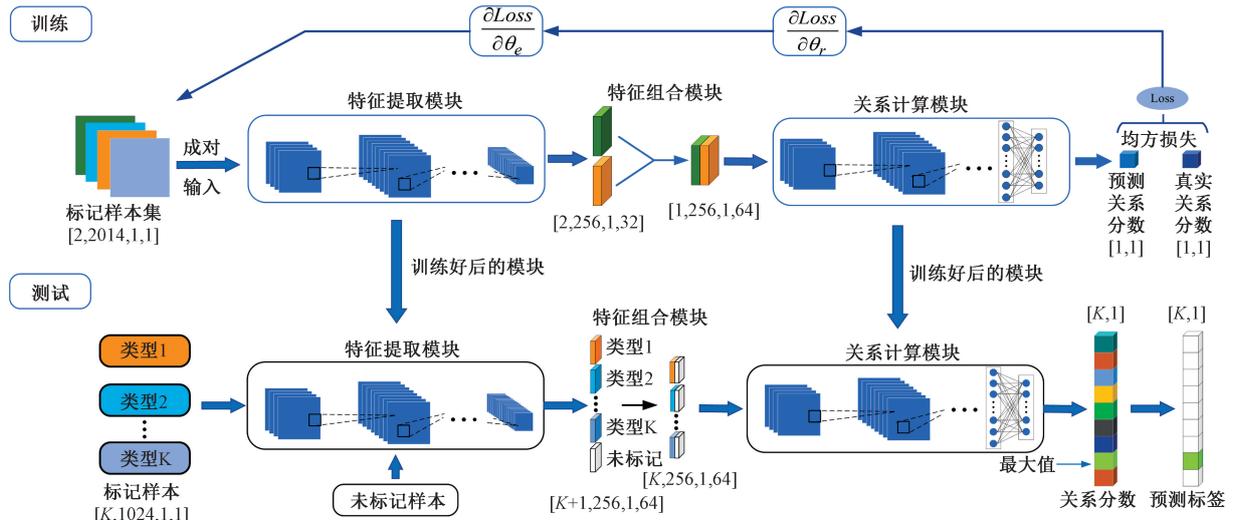


图 7 深度嵌入关系空间下齿轮故障诊断框架

Fig. 7 The gear fault diagnosis framework in the deep embedding relation space

表 4 不同方法进行故障诊断的结果

Table 4 The fault diagnosis results of different methods

方法	验证准确率/%		测试准确率/%	
	平均值	标准差	平均值	标准差
CNN	79.64	0.98	77.95	1.66
CNN+Dropout	81.57	1.53	80.90	1.30
标记传播	54.84	0.00	53.76	0.00
深度自编码器	45.17	1.08	42.44	2.30
孪生网络	73.76	5.79	72.57	6.49
PAR 网络	90.05	2.00	88.65	1.77
所提出方法	98.67	0.75	98.59	0.89

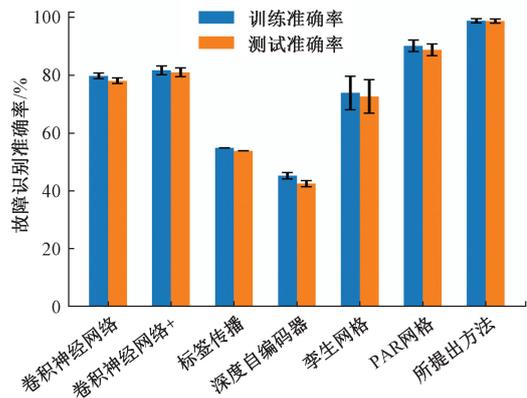


图 8 不同方法的分类结果

Fig. 8 The classification results of different methods

方法,所提出方法的故障辨识精度分别提高了 20.64% 和 17.69%,表明所提出方法能够有效的避免网络过拟合所导致的模型退化问题。相比于孪生网络和 PAR 网络,所提出方法的故障诊断准确率分别提高了 26.02% 和 9.94%,实验结果表明,通过所提出的伪标签学习方法能够有效的利用无标记样本所蕴藏的特征信息,从而增强模型的泛化能力和故障辨识能力。此外,相比于其它故障诊断方法,标签传播和深度自编码器方法在少量标记样本条件下表现出较差的故障模式分类性能。

为进一步对比传统方法与所提出方法的故障诊断性能,本部分引入 t 分布随机邻域嵌入 (t-distributed stochastic neighbor embedding, t-SNE)<sup>[33]</sup> 进行可视化分析。t-SNE 是一种非线性降维算法,将 t-SNE 技术应用于对比方法和本文提出的诊断方法,获取的降维可视化图如图 9 所示。

从图 9 中可以观察到,原始振动信号点随机分布于二维可视化图中,单从可视化图不能区分每个样本的健康状态。相比之下,基于深度学习的故障诊断方法具有较好的可视化效果,但仍然有部分特征点存在重叠,尤其是具有不同故障严重程度度的齿轮齿顶磨损故障类型,并最终导致故障识别精度较低。相较而言,所提出的基于标记样本扩充的半监督诊断方法具有较好的特征提取和故障辨识能力,获得了良好的聚类性能,能将不同故障类型的特征点进行很好的聚拢,并具有明显的边界。基于良好的分类性能,所提出的半监督故障诊断模型能够准确地实现少量标记样本条件下齿轮故障模式分类。

为验证所提出方法的性能,本文采用混淆矩阵对齿轮故障分类情况进行进一步分析。在混淆矩阵中,纵轴表示测试样本所属的真实故障类型,横轴表示所提出方法预测的故障类型,如图 10 所示。

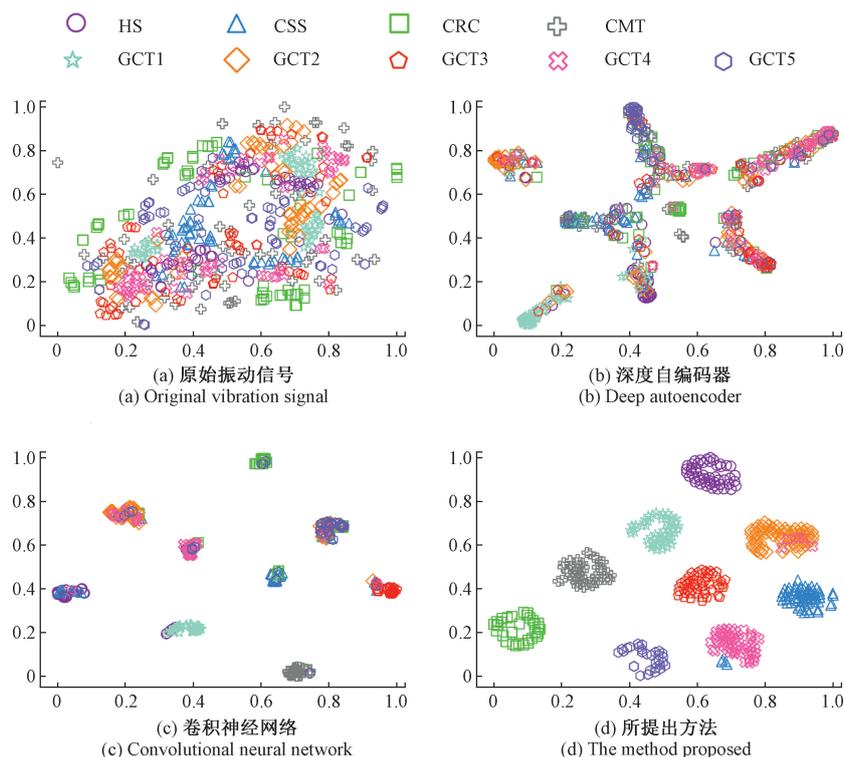


图9 不同故障诊断方法 t-SNE 降维可视化图

Fig. 9 The feature visualization after t-SNE dimensionality reduction of different fault diagnosis methods

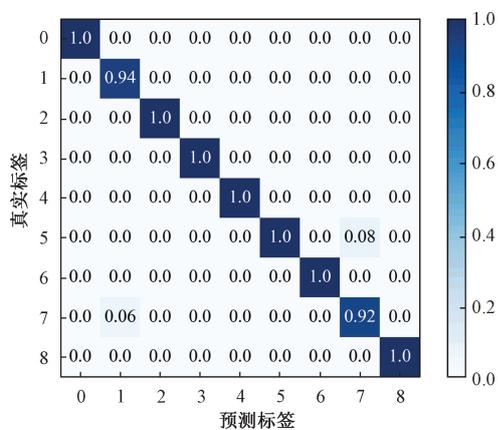


图10 所提出方法的混淆矩阵

Fig. 10 The confusion matrix of the proposed method

该实验在测试样本集上的整体故障诊断准确率为 98.38%。从图 10 中可以观察到,除了故障类型 1 (GSS) 和故障类型 7 (GCT4) 外,所提方法在所有齿轮健康状态下都具有良好的分类性能。其中,6% 的 GSS 样本被错误识别为 GCT4, 8% 的 GCT4 样本被错误识别为 GCT2。造成上述错误分类的主要原因在于 GCT2 和 GCT4 故障类型相同,仅其故障严重程度存在微小差异,两种齿轮健康状态之间的故障特征高度相似,由此造成部分故障样本错误分类。尽管如此,所提出方法在齿轮箱故障诊断中

仍能达到较高的分类精度,能够满足实际工业的需求。

## 2) 不同标记样本比例下的齿轮故障诊断结果分析

在伪标签学习策略中,不同的标记样本比例设定会对故障诊断结果产生一定的影响。为了研究伪标签学习时所标定样本的比例(即采样率)对实验结果的影响,本部分进行了 4 组实验,分别选择了 50%、60%、70% 以及 80% 的无标记样本赋予其伪标签,并用于深度关系网络模型的再训练。不同采样率设置下所对应的故障诊断结果如表 5 所示。

表5 不同采样率下故障诊断结果

Table 5 Experimental results under different sampling rates

采样率	验证准确率/%		测试准确率/%	
	平均值	标准差	平均值	标准差
0.5	96.22	0.87	96.01	1.02
0.6	97.80	0.98	97.44	1.11
0.7	98.32	0.85	98.16	0.92
0.8	98.67	0.75	98.59	0.89

如表 5 所示,在少量标记样本的情况下,随着采样率的增加,所提出的半监督故障诊断方法的故障辨识精度也随之上升。这是因为,深度关系网络通过构建对输入样本形式能够生成大量的学习任务,从而有效的避免

模型过拟合问题;通过所提出的伪标签学习策略,能够准确的实现标记样本扩充,最大程度上防止因错误标记所带来的模型退化问题。此外,通过渐进循环的再训练策略能够逐步增强关系网络的泛化能力,对最终的故障诊断精度的提升具有积极影响。

### 3) 消融实验分析

为进一步论证所提出半监督诊断方法的性能,本部分进行系列消融实验以研究所提出方法不同模块对最终故障诊断结果的影响。具体而言,实验分别对深度关系网络和伪标签学习方法进行消融,经消融之后的齿轮故障辨识结果如表6所示。

表6 消融实验结果

Table 6 The results of the ablation experiment

方法	验证准确率/%		测试准确率/%	
	平均值	标准差	平均值	标准差
去掉关系计算网络	69.12	4.96	67.89	4.42
去掉伪标签学习	87.34	3.97	85.41	4.63
所提出方法	98.67	0.75	98.59	0.89

由表6可知,与所提出的半监督故障诊断方法相比,在去掉关系网络部分后,故障分类准确率下降到67.89%。这是因为去掉关系网络部分后,所提出的半监督故障诊断方法退化为传统的伪标签学习方法。传统的伪标签学习方法利用深度神经网络对未标记样本进行故障类型预测,通过预测结果生成相应伪标签用于模型再训练。然而,在少量标记样本条件下,模型过拟合问题会严重的限制神经网络的预测精度,对最终故障分类精度产生消极作用。此外,伪标签学习方法直接将所有被赋予伪标签的无标记样本用于模型再训练,错误伪标签的引入不但不能起到增强模型泛化能力的作用,反而使得模型退化从而导致模型故障辨识精度降低。

由表6分析,去掉伪标签学习部分后,故障分类准确率下降至85.41%。这是因为,去掉伪标签学习部分后,所提出的半监督故障诊断方法退化为深度关系网络方法。深度关系网络通过构建对输入样本形式可以生成大量的学习任务,在一定程度上能有效的防止因模型过拟合现象所导致的模型退化问题。但在少量标记样本条件下,关系网络的泛化能力不强,从而使得其故障辨识精度较低。

通过上述消融实验分析,深度关系网络和伪标签学习策略在所提出的半监督故障诊断方法中起着重要作用。通过渐进循环的标记样本扩充方法能够有效且准确的实现无标记样本伪标签预测和深度关系网络泛化能力增强,对故障辨识精度的提升产生重要影响。

## 4 结 论

针对少量标记样本条件下齿轮故障诊断问题,提出了一种深度嵌入关系空间下齿轮箱标记样本扩充及其半监督故障诊断方法。该方法将样本关系衡量和伪标签学习策略集成到一个渐进的框架中以实现标记样本扩充和模型泛化能力增强。

该方法通过深度关系网络构造了一个强大的嵌入关系空间,减少了对标记样本的依赖;同时,引入了一种新颖的伪标签学习策略,能有效的利用未标记样本信息,实现标记样本集的扩充,从而提高了模型的泛化能力。在有限的标记样本条件下(标记样本占比为4%)进行齿轮箱故障辨识,实验结果表明,所提出半监督故障诊断方法取得了良好的故障诊断效果,具有较高的故障辨识精度和较为稳定的诊断能力。

### 参考文献

- [1] 王靖岳,王浩天,郭立新. 齿轮传动系统故障诊断技术的研究进展[J]. 机械传动,2016,40(8):185-192.  
WANG J Y, WANG H T, GUO L X. Research progress on fault diagnosis technology of gear transmission system[J]. Mechanical Transmission,2016,40(8):185-192.
- [2] 雷亚国,何正嘉,林京,等. 行星齿轮箱故障诊断技术的研究进展[J]. 机械工程学报,2011,47(19):59-67.  
LEI Y G, HE ZH J, LIN J, et al. Research advances of fault diagnosis technique for planetary gearboxes [J]. Journal of Mechanical Engineering, 2011, 47(19):59-67.
- [3] 赵丽娟,刘晓东,李苗. 齿轮故障诊断方法研究进展[J]. 机械强度,2016,38(5):951-956.  
ZHAO L J, LIU X D, LI M. Research progress of gear fault diagnosis methods [J]. Mechanical Strength, 2016, 38(5):951-956.
- [4] 蒋永华,程光明,阚君武,等. 基于NGA优化SVM的滚动轴承故障诊断[J]. 仪器仪表学报,2013,34(12):2684-2689.  
JIANG Y H, CHENG G M, KAN J W, et al. Rolling bearing fault diagnosis based on NGA optimized SVM [J]. Chinese Journal of Scientific Instrument, 2013, 34(12):2684-2689.
- [5] CERRADA M, ZURITA G, CABRERA D, et al. Diagnosis in spur gears based on genetic algorithm and random forest [J]. Mechanical Systems and Signal Processing, 2016,(70-71):87-103.
- [6] ALI J B, FNAIECH N, SAIDI L, et al. Application of

- empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals [J]. *Applied Acoustics*, 2015, 89: 16-27.
- [7] SHAO H D, JIANG H K, LI X Q, et al. Intelligent fault diagnosis of rolling bearing using deep wavelet auto-encoder with extreme learning machine [J]. *Knowledge Based Systems*, 2018, 140:1-14.
- [8] YAN H R, QIN Y, XIANG SH, et al. Long-term gear life prediction based on ordered neurons LSTM neural networks [J]. *Measurement*, 2020, 165:108205.
- [9] ZHAO R, YAN R Q. Deep learning and its applications to machine health monitoring [J]. *Mechanical Systems and Signal Processing*, 2019, 115:213-237.
- [10] 余永维, 殷国富, 殷鹰, 等. 基于深度学习网络的射线图像缺陷识别方法 [J]. *仪器仪表学报*, 2014, 35(9):2012-2019.
- YU Y W, YIN G F, YIN Y, et al. Radiographic image defect recognition method based on deep learning network [J]. *Chinese Journal of Scientific Instrument*, 2014, 35(9): 2012-2019.
- [11] ZHAO J F, MAO X, CHEN L J. Speech emotion recognition using deep 1D & 2D CNN LSTM networks [J]. *Biomedical Signal Processing and Control*, 2019, 47: 312-323.
- [12] 孔子迁, 邓蕾, 汤宝平, 等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法 [J]. *仪器仪表学报*, 2019, 40(6):221-227.
- KONG Z Q, DENG L, TANG B P, et al. Deep learning fault diagnosis method for planetary gearbox based on time-frequency fusion and attention mechanism [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(6): 221-227.
- [13] CHANG X, TANG B P, TAN Q, et al. One-dimensional fully decoupled networks for fault diagnosis of planetary gearboxes [J]. *Mechanical Systems and Signal Processing*, 2020, 141:106482.
- [14] 包萍, 刘运节. 不平衡数据集下基于生成对抗网络的改进深度模型故障识别研究 [J]. *电子测量与仪器学报*, 2019, 33(3):176-183.
- BAO P, LIU Y J. Research on improved depth model fault recognition based on generative adversarial network in unbalanced data set [J]. *Journal of Electronic Measurement and Instrument*, 2019, 33(3):176-183.
- [15] 陈志强, 陈旭东, José Valente de Olivira, 等. 深度学习在设备故障预测与健康中的应用 [J]. *仪器仪表学报*, 2019, 40(9):206-226.
- CHEN ZH Q, CHEN X D, JOSE V D O, et al. Application of deep learning in equipment fault prediction and health management [J]. *Chinese Journal of Scientific Instrument*, 2019, 40(9):206-226.
- [16] 胡芑庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法 [J]. *机械工程学报*, 2019, 55(7):9-18.
- HU N Q, CHEN H P, CHENG ZH, et al. Fault diagnosis method of planetary gearbox based on empirical mode decomposition and deep convolutional neural network [J]. *Chinese Journal of Mechanical Engineering*, 2019, 55(7):9-18.
- [17] WANG H, XU J W, YAN R Q, et al. Intelligent bearing fault diagnosis using multi-head attention-based CNN [J]. *Procedia Manufacturing*, 2020, 49:112-118.
- [18] 宫文峰, 陈辉, 张美玲, 等. 基于深度学习的电机轴承微小故障智能诊断方法 [J]. *仪器仪表学报*, 2020, 41(1):195-205.
- GONG W F, CHEN H, ZHANG M L, et al. Intelligent diagnosis method of motor bearing micro fault based on deep learning [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(1): 195-205.
- [19] LI Q K, TANG B P, DENG L, et al. Deep balanced domain adaptation neural networks for fault diagnosis of planetary gearboxes with limited labeled data [J]. *Measurement*, 2020, 156: 107570.
- [20] SHAHANI B M, LANDGREBE D A. The effect of unlabeled samples in reducing the small sample size problem and mitigating the Hughes phenomenon [J]. *IEEE Trans Geosci Remote Sensing*, 1994, 32: 1087-1095.
- [21] ZHANG K, TANG B P, QIN Y, et al. Fault diagnosis of planetary gearbox using a novel semi-supervised method of multiple association layers networks [J]. *Mechanical Systems and Signal Processing*, 2019, 131:243-260.
- [22] YU K, MA H, LIN T R, et al. A consistency regularization based semi-supervised learning approach for intelligent fault diagnosis of rolling bearing [J]. *Measurement*, 2020, 165:107987.
- [23] WANG ZH Y, YAO L G, CAI Y W, et al. Mahalanobis semi-supervised mapping and beetle antennae search based support vector machine for wind turbine rolling bearings fault diagnosis [J]. *Renew Energy*, 2020, 155: 1312-1327.
- [24] 张鑫, 郭顺生, 李益兵, 等. 基于拉普拉斯特征映射

- 和深度置信网络的半监督故障识别[J]. 机械工程学报, 2020, 56(1): 69-81.
- ZHANG X, GUO SH SH, LI Y B, et al. Semi-supervised fault recognition based on Laplacian eigenmap and deep belief network [J]. Acta Mechanical Engineering, 2020, 56 (1): 69-81.
- [25] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018:1199-1208.
- [26] LEE D. Pseudo-label: The simple and efficient semi-supervised learning method for deep neural networks. workshop on challenges in representation learning[C]. International Conference on Machine Learning (ICML), 2013.
- [27] HUANG J B, DONG Q, GONG S G, et al. Unsupervised deep learning by neighbourhood discovery [C]. In Proceedings of the International Conference on Machine Learning (ICML), 2019.
- [28] ZHANG SH L, TANG J. Integrating angle-frequency domain synchronous averaging technique with feature extraction for gear fault diagnosis [J]. Mechanical Systems and Signal Processing, 2018, 99:711-729.
- [29] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computer Science, 2012, 3(4): 212-223.
- [30] ZHOU D Y, BOUSQUET O, LAL T N, et al. Learning with local and global consistency [C]. Conference and Workshop on Neural Information Processing Systems (NIPS), 2003, DOI:10.1007/s11222-007-9033-z.
- [31] ZHANG A S, LI S B, CUI Y X, et al. Limited data rolling bearing fault diagnosis with few-shot learning[J]. IEEE Access, 2019, 7:110895-110904.
- [32] WU Z Y, LI Y W, GUO L H, et al. PARN: Position-aware relation networks for few-shot learning [C]. International Conference on Computer Vision (ICCV), 2019: 6658-6666.
- [33] MAATEN L V D, HINTON G. Visualizing data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9:2579-2605.

### 作者简介



吕枫, 2020年于石河子大学获得学士学位。现为重庆大学硕士研究生, 主要研究方向为机械故障诊断。

E-mail: lvfeng1114@163.com

**Lyu Feng** received his B. Sc. degree from Shihezi University in 2020. He is currently a master student at Chongqing University. His main research interests include mechanical fault diagnosis.



王义(通信作者), 2011年于西南交通大学获得学士学位, 2017年于西安交通大学获得博士学位, 现为重庆大学机械工程学院副教授, 主要研究方向为智能信息处理与旋转机械故障诊断。

E-mail: wyye@cqu.edu.cn

**Wang Yi** (Corresponding author) received his B. Sc. degree from Southwest Jiaotong University in 2011, and received his Ph. D. degree from Xi'an Jiaotong University in 2017. He is currently an associate professor at Chongqing University. His main research interests include intelligent information processing and rotating machinery fault diagnosis.



王平, 中国航发湖南动力机械研究所工程师, 主要研究方向为航空发动机性能测试与故障诊断。

E-mail: wp608@sina.com

**Wang Ping** is an engineer of AECC Hunan Aviation Powerplant Research Institute. His main research interests include aeroengine performance test and fault diagnosis.