

DOI: 10.13382/j.jemi.B2205952

小样本下时序注意力边界增强原型网络的 齿轮箱故障诊断方法^{*}

韩 延^{1,2} 李 超^{1,2} 黄庆卿^{1,2} 文 瑞¹ 张 焱^{1,2}

(1. 重庆邮电大学自动化学院 重庆 400065; 2. 重庆邮电大学工业互联网研究院 重庆 401120)

摘 要:针对小样本条件下原型网络在提取特征过程中会丢失振动数据的时序特征,且未修正样本在度量空间中的分布导致模型精度低的问题,提出一种时序注意力边界增强原型网络的齿轮箱故障诊断方法。首先,通过构建时间序列注意力模块,建立通道间的时序特征依赖,获得通道时序融合特征;然后,在计算类原型之后,增加邻边界损失以修正度量空间中的故障特征类内和类间分布,明确类原型的表征边界。最后,通过计算测试样本与类原型的欧氏距离,输出故障诊断结果。实验表明,在小样本条件下本文所提方法相比其他方法具有更高的故障诊断精度。

关键词:故障诊断;小样本;原型网络;度量学习;时序注意力

中图分类号: TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460.1520;510.4030

Boundary-enhanced prototype network with time-series attention for gearbox fault diagnosis under limited samples

Han Yan^{1,2} Li Chao^{1,2} Huang Qingqing^{1,2} Wen Rui¹ Zhang Yan^{1,2}

(1. Automation College, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Institute of Industrial Internet, Chongqing University of Posts and Telecommunications, Chongqing 401120, China)

Abstract: To address the problem that the time-series characteristics of vibration data are lost in the process of feature extraction in the prototype network, and the distribution of samples in the metric space is not corrected which results in low model accuracy under few-shot task, this paper proposes a new boundary-enhanced prototype network with time-series attention for gearbox fault diagnosis. First, the time-series fusion features of the channels are obtained by building a time-series attention module to establish the time-series feature dependencies between channels. Then, after calculating the class prototypes, the near-neighbor boundary loss is added to correct the intra- and inter-class distributions of the fault features in the metric space to clarify the representation boundaries of the class prototypes. Finally, the fault diagnosis results are output by calculating the Euclidean distance between the test sample and the class prototype. The experiments show that the proposed method in this paper has higher fault diagnosis accuracy compared with other methods under small sample conditions.

Keywords: fault diagnosis; few-shot task; prototype network; metrics learning; time-series attention

0 引 言

齿轮箱作为重大装备的关键传动系统之一,对其的运行状态有着至关重要的影响^[1]。由于长期工作在恶劣环境下,齿轮箱经常存在潜在故障,容易导致机器停机或生产事故^[2]。因此,开展齿轮箱故障诊断方法的研究,对

保障重大装备的运行安全和可靠性是具有重要意义^[3]。

近年来,鉴于深度学习在非线性表示和自动特征提取能力方面的优势,卷积神经网络^[4]、深度自动编码器^[5]和深度残差网络^[6]等深度学习方法在故障诊断领域得到了广泛应用。然而,在实际工程应用中,对数据标记故障费时费力,难以获取充足可用的故障样本,导致深度学习故障诊断模型容易发生过拟合,诊断性能严重下降^[7]。

收稿日期: 2022-11-01 Received Date: 2022-11-01

^{*} 基金项目:国家重点研发计划项目(2021YFB3301000)、国家自然科学基金(51605065)、中国博士后科学基金(2022MD713687)、重庆市博士后科学基金项目(cstc2021jcyj-bshX0094)资助

为了解决小样本导致基于传统深度学习故障诊断方法精度不高的问题,迁移学习^[8]、数据增强^[9]和元学习^[10]等多种小样本下故障诊断方法被提出。然而,基于迁移学习的方法在面对复杂条件的目标域时容易存在负迁移的问题^[11]。基于数据增强方法的生成数据无法提供更多有效的额外信息^[12]。相比之下,基于元学习的方法,由于其泛化能力和工程应用的可移植性,使得该方法在实际应用中获得了广泛的关注^[13]。其中,原型网络(prototypical network, ProNet)^[14]作为常用的元学习方法,在故障诊断领域已经开展了大量的研究。例如,Jiang等^[15]提出了一种双分支原型网络用于故障诊断,通过利用时域和频域振动信号的信息提高了故障诊断的准确率。Sun等^[16]提出了一种基于残差注意力的原型网络,通过残差注意力机制有效捕获有限样本下全局依赖特征进行了故障诊断。然而,上述方法未考虑原型网络对振动信号的时序特征提取能力不足,以及只通过欧氏距离进行度量分类,忽略从样本中得到样本分布统计规律,导致模型识别精度难以保证。

为解决上述问题,本文提出一种时序注意力边界增强原型网络的齿轮箱故障诊断方法。首先,在网络特征提取阶段之后,添加时序注意力模块,对故障特征进行时序学习,建立通道间的时序特征依赖,获得通道时序融合特征。其次,在原型网络的度量空间中,通过近邻边界损失,利用样本分布统计规律,修正特征整体在度量空间中的分布,明确类原型的表征边界。通过对比不同方法,证明了本文所提方法在面对小样本条件下的齿轮箱故障诊断任务中,具有更好的有效性和可行性。

1 原型网络

ProNet 是一种基于度量学习的元学习方法,与传统深度学习方法不同,ProNet 通过每个类别的很少样本数据来计算类原型,并利用欧氏距离找到邻近类别来确定待分类样本的分类结果。ProNet 将训练数据集 D_{train} 划分为支撑集 $S_c = \{(x_i, y_i)\}_{i=1}^{n_s}$ 和查询集 $Q_c = \{(\tilde{x}_i, \tilde{y}_i)\}_{i=1}^{n_q}$, 其中 $x_i \in X^D$ 为 D 维的原始信号向量, $y_i \in \{1, \dots, K\}$ 为每类原始信号的标签。支撑集包含 K 类故障状态下共计 n_s 个有标签样本的数据集;查询集包含 n_q 个有标签样本的数据集。训练集样本总数 $N \geq n_s + n_q$ 。如图1所示,ProNet 假设每类特征样本围绕可以代表整个类别的原型进行聚类,并将每个类别原型与查询样本进行比较,以确定查询集标签,该方法可以有效地度量查询集与类原型之间的相似关系。

卷积网络通过可学习的特征提取函数 $f(\cdot)$ 将支撑集数据 $x_i \in X^D$ 从低维映射到高维度量空间,并获得输入




图1 原型网络示意图

Fig. 1 Diagram for the ProNet

数据的特征向量 $f(x_i)$ 。在高维度量空间中,每类原型 p_c 通过计算来自网络学习到的支撑集特征向量的均值获得。具体如下:

$$p_c = \frac{1}{|n_c|} \sum_{i=1}^k f(x_i^{S_c}) \quad (1)$$

其中, n_c 是支撑集同类样本的数量。

查询集特征向量 $f(x_i^{Q_c})$ 与类原型 p_c 之间的相似度通过距离函数 F_{l_2} 来度量,并在之后计算 $x_i^{Q_c}$ 的分类概率,具体如下:

$$\hat{y}_i^Q = \underset{c}{\operatorname{argmax}} \frac{e^{-F_{l_2}(p_c, f(x_i^{Q_c}))}}{\sum_{c=1}^K e^{-F_{l_2}(p_c, f(x_i^{Q_c}))}} \quad (2)$$

其中, F_{l_2} 为欧氏距离。

$$F_{l_2}(p_c, x_i^{Q_c}) \triangleq \|p_c - f(x_i^{Q_c})\|_2 \quad (3)$$

2 时序注意力边界增强原型网络

2.1 时序注意力模块

振动信号作为典型的时序信号,存在冲击、振荡等关键时刻的重要信息^[17],对其进行时序分析并提取时序特征,对确定故障类型和提升故障诊断信息起到至关重要的作用^[18]。然而,现有的原型网络方法通过卷积网络获得的故障特征,各个通道表征了故障的不同时刻特征信息^[19],但是各个通道之间相互独立,失去了原始信号重要信息之间的时序依赖性,且无法根据不同信息的重要程度自动提取关键信息,因此网络无法获得更具判别性的故障特征,故障诊断精度不高。针对该问题,本文提出了时序注意力模块(time-series attention module, TAM),通过注意力机制使网络获取关键时序特征,获得更具判

别性的故障特征,提升故障诊断精度。

时序注意力模块如图 2 所示,主要由门控循环单元 (gated recurrent unit, GRU) 和压缩激励模块 (squeeze-excitation block) 组成。其中,门控循环单元用于初步提取输入特征 U_C^L 各通道间的时序依赖性,获取时序融合特征向量 H_C^L ;压缩激励模块筛选 H_C^L 通道中的关键时序特征 h_c^L ,并对其加权获得通道时序融合特征 $\tilde{H}_C^L$ 。

设 $U_C^L = \{u_c^1, u_c^2, \dots, u_c^L\}$ 为特征长度 L 通道数 C 的故障特征,将每个时刻 $t \in [1, L]$ 向量长度为 C 的故障特征 u_c^t 输入门控循环单元 GRU。GRU 将以通道数 C 作为特征时间戳长度,学习每个时间戳 t 上的通道时序特征,并输出为 $H_C^L = \{h_c^1, h_c^2, \dots, h_c^L\}$,具体计算为:

$$g_t = \sigma(W_r[h_c^{t-1}, u_c^t] + b_r) \quad (4)$$

$$h_c^t = \tanh(W_h[g_t, h_c^{t-1}, u_c^t] + b_h) \quad (5)$$

其中, h_c^{t-1} 、 h_c^t 分别为时间戳 $t-1$ 的状态向量和时间戳 t 的状态向量; g_t 为门控向量; W_r 和 b_r 为复位门的参数; W_h 和 b_h 为更新门的参数; σ 为 Sigmoid 激活函数。

为了进一步获得关键时刻的时间序列特征,通过压缩操作 F_{sq} , 对 h_c^L 进行全局平均池化 (global average pooling, GAP) 聚合维度,以获得时序特征通道描述符 z_c^L , 定义如下:

$$z_c^L = F_{sq}(h_c^L) = \frac{1}{L} \sum_{i=1}^L h_c^i \quad (6)$$

为了充分获取通道依赖性,利用多层感知机 (multi-layer perceptron, MLP) 对通道描述符 z_c^L 进行激励操作 F_{ex} , 并利用 Sigmoid 函数产生每个描述符的综合权重,最终将这些权重重新应用到 H_C^L 上获得最终输出通道时序融合特征 $\tilde{H}_C^L = \{\tilde{h}_c^1, \tilde{h}_c^2, \dots, \tilde{h}_c^L\}$ 。具体计算如下:

$$s_c^L = F_{ex}(z_c^L, W) = \sigma(g(z_c^L, W)) = \sigma(W_2 \delta(W_1 z_c^L)) \quad (7)$$




图 2 时序注意力模块结构

Fig. 2 The structure of TAM

近邻损失示意图如图 3 所示。损失第 1 项近邻损失的目的是为了拉近同类样本与类原型之间的距离,降低

$$\tilde{h}_c^L = F_{scale}(h_c^L, s_c^L) = s_c^L h_c^L \quad (8)$$

其中, W 为多层感知机的权重, s_c^L 是加权通道描述符,用于筛选出更关键的时序特征; δ 是每层感知机的激活函数, F_{scale} 是指加权通道 s_c^L 和时序特征向量 h_c^L 之间相乘。

2.2 近邻边界损失

由于原型网络在度量空间中,使用欧氏距离进行度量分类,没有关注特征的类内方差、类间方差等统计规律,使得在度量空间中的特征因为方差问题,导致特征分布类内离散类间混叠,原型表征边界不清晰。为了克服特征在度量空间中的分布问题,本文引入了近邻边界损失 (near-neighbor boundary loss, NB loss) 修正高维空间中的特征分布,明确原型的表征边界。近邻边界损失定义如下:

$$L_{NB} = y_{il} \frac{1}{2n_s} \sum_{i=1}^{n_K} F_{l2}(p_i, x_i^{s_c}) + (1 - y_{il}) \frac{1}{n_K} \sum_{i,l=1}^{n_K} [F_{l2}(p_i, x_i^{s_c}) - F_{l2}(p_i, x_l^{s_c})]_+ \quad (9)$$

其中, N_K 为样本的类别数量, i, l 为故障类型标签, p_i 为标签为 i 的类原型, $x_i^{s_c}, x_l^{s_c}$ 为标签为 i, l 的支撑集样本高维特征向量。 $[Z]_+ = \max(Z, 0)$ 表示标准铰链损失。当 $i = l$ 时, $y_{il} = 1$, 此时,计算损失第 1 项近邻损失。首先计算近邻距离,即标签为 i 的类原型 p_i 以及所有特征 $x_j^{s_c}$ 之间的欧氏距离,然后对所有标签类型的距离求和获得近邻损失。当 $i \neq l$ 时, $y_{il} = 0$, 此时,计算损失第 2 项,边界损失。首先计算近邻距离,然后计算入侵距离,即标签为 i 的类原型 p_i 与标签为 j 的所有特征 $x_j^{s_c}$ 之间的欧氏距离;最后,通过标准铰链损失获得近邻距离与入侵距离的差值。如果该项损失大于 0,表示有异类样本入侵到类原型的表征边界之内。

类内方差使同类样本间的类内距离更加聚集。损失第 2 项边界损失的目的是为了排斥异类样本同某个类原型的

距离,增大类间方差使得类原型表征范围内没有其他异类样本以明确原型表征边界,并使得异类样本群之间的分布更加离散,提升分类精度。




图3 近邻损失示意图

Fig. 3 Diagram for the near-neighbor boundary loss

2.3 TBPB 整体框架

TBPB 整体框架如图4所示,首先,通过一维卷积网络作为特征提取函数 $F(\cdot)$ 学习样本的故障特征;其次,通过时序注意力机制学习故障特征的通道时序依赖,获得通道时序融合特征;之后,在度量空间内利用每类样本的所有通道时序融合特征计算类原型,并利用近邻损失修正特征分布并明确原型表征边界;最后利用类原型同样本间的距离输入故障诊断结果。

对训练集数据 D_{train} , 特征提取函数 $F(\cdot)$ 将其映射到高维空间中,获得样本的故障特征 U_C^L , 定义为:

$$U_C^L = F(x_i) \quad (10)$$

然后,根据式(4)~(8)获取通道时序融合特征 $\tilde{H}_C^L$, 对支撑集数据利用式(1)计算类原型 p_c , 并对支撑集特征根据式(9)计算近邻边界损失 L_{NB} , 对查询集特征根据式(2)得到模型输出,并计算分类损失 L_{CE} , 定义如下:

$$L_{CE} = - \sum_{i=1}^N y_i^0 \log(\hat{y}_i^0) \quad (11)$$

其中, y_i^0 为样本真实标签, $\hat{y}_i^0$ 为模型的预测标签。

模型的总损失 L_{total} 为分类损失和近邻边界损失之和,定义如下:

$$L_{\text{total}} = L_{CE} + \alpha L_{NB} \quad (12)$$

其中, α 为动态调整系数,目的是确保优化方向始终偏向分类损失,同时保证近邻边界损失不会失效。具体定义如下:

$$\alpha = \frac{L_{CE}}{L_{CE} + L_{NB}} \quad (13)$$

模型映射函数 $F(\cdot)$ 的可更新参数为 θ_F , 总优化目标为:

$$L_{\text{total}}(\theta_F) = \min(L_{CE}(\theta_F) + \alpha L_{NB}(\theta_F)) \quad (14)$$

使用随机梯度下降算法对各模块参数 θ 进行更新,

参数 θ 更新如下:

$$\theta_F \leftarrow \theta_F - \eta \left(\frac{\partial L_{CE}}{\partial \theta_F} + \alpha \frac{\partial L_{NB}}{\partial \theta_F} \right) \quad (15)$$

其中, η 为模型的学习率。

3 小样本下时序注意力边界增强原型网络的齿轮箱故障诊断流程

本文所提方法的总体流程如图5所示,小样本条件下基于 TBPB 的齿轮箱故障诊断方法分为3个步骤:数据预处理与数据集构建, TBPB 网络模型的建立与训练, 验证模型故障诊断性能。

1) 数据预处理与数据集构建:对采集到的原始数据根据故障类型进行标记,并将数据切分为支持集、查询集和测试集;

2) 网络模型的建立与训练:搭建 TBPB 网络,使用支撑集和查询集的少量数据进行模型训练,对模型参数进行优化;

3) 模型故障诊断性能验证: TBPB 网络模型训练完成后,使用测试集进行验证,计算故障识别精度、绘制预测结果混淆矩阵以及进行可视化分析,证明模型的有效性。

4 实验验证

4.1 实验数据集介绍

为了验证所提出方法的有效性,本文利用动力传动系统诊断模拟器(DDS)进行故障模拟实验,图6展示了DDS的主要结构。该实验在12.8 kHz采样频率、20 Hz电机转速下,采集了平行轴齿轮箱8种不同的故障状态,如表1所示。采集后,原始振动信号被划分为800个样本,每个样本长度1 024,如图7所示。之后,对于每个故障状态,从800个样本中随机抽取50个样本作为训练样本,750个样本作为测试样本。

本文中实验进行了4组不同任务设置实验,训练样本会根据不同任务设置划分为支撑集和查询集,支撑集和查询集的样本总和小于等于训练样本。除了5-shot任务支撑集样本为4个外,其余任务支撑集样本均为8个。

4.2 实验参数设置

为了验证所提出方法的有效性,本节利用实验数据对比其他相关方法进行了实验验证。所有实验均在Python 3.7和框架TensorFlow-2.1.0下使用Intel(R) Core(TM) i5-10400F CPU、NVIDIA GeForce GTX 1080和12 GB RAM进行。




图 4 TBPB 整体框架示意图

Fig. 4 Diagram of TBPB overall framework.




图 5 本文提出方法的总体流程

Fig. 5 The overall flow of the proposed method




图 6 轴承测试台

Fig. 6 The bearing test bench

为了保证实验的公平性,所有方法在实验过程中都使用相同的网络架构和超参数。网络架构由 6 层卷积运算、1 个时序注意力模块组成。每层卷积运算操作分别包括卷积层、最大池化层、批归一化层和激活层,激活层

表 1 数据集描述

Table 1 Description of the Dataset

标签	状态	描述
0	B1	轴承外圈故障
1	B2	轴承内圈故障
2	B3	轴承滚动体故障
3	G1	齿轮根部故障
4	G2	齿轮偏心故障
5	G3	齿轮断齿故障
6	G4	齿轮表面磨损故障
7	G5	齿轮缺齿故障

是使用线性修正函数,使用 Adam 优化器对网络进行更新,学习率为 0.001,训练批次大小为 64,每次训练 100 个 epoch。为避免随机初始化对实验结果的波动,在每一组实验中固定 10 个不同的随机数种子作为随机序列,去除每次实验的最差最好结果,将剩余 8 次实验结果的平




图 7 轴承时域波形图

Fig. 7 The time domain waveform of the bearing

均值作为实验的结果。

4.3 对比实验与结果分析

为验证本文所提方法对于齿轮箱故障诊断的有效性,将 TBPN 与原型网络 (prototype network, ProNet)、有效注意力原型网络 (efficient attention prototypical net, EAPN)^[20]、基于度量学习的故障诊断方法 (metric learning-based fault diagnosis, MerNet)^[10] 以及时序注意力改进的原型网络 (TAMPN) 和近邻边界损失改进的原型网络 (NBPN) 进行对比分析。

4 种任务下,故障分类结果如表 2 和图 8 所示。从表 2 和图 8 中可知,ProNet 在 5-shot、10-shot、15-shot、20-shot 下精度分别为 65.35%、74.25%、84.56%、86.72%,在小样本下取得了一定效果,但其故障诊断还需要进一步提高。

基于注意力改进的 EAPN 和 TAMPN 方法,均有效的改进了原型网络在各个任务下的性能。在 5-shot 任务中,本文所提注意力方法与 ProNet 相比,诊断精度提高了 17.05%,与 EAPN 方法相比也提升了 12.42%。在其余 3 个任务中,TAMPN 与 EAPN 方法相比,分别提升了 8.53%、3.57%、2.28%。结果表明,本文所提的时序注意力模块通过关注数据的时序特性,能够获得更具判别性的故障特征,提升了模型的故障诊断性能。

表 2 对比实验结果

Table 2 Results of comparative experiments (%)

方法	测试平均准确率+标准差			
	5-shot	10-shot	15-shot	20-shot
ProNet	65.35±0.33	74.25±0.30	84.56±0.13	86.72±0.24
EAPN	69.98±0.31	77.11±0.08	85.14±0.08	87.42±0.03
MerNet	68.49±0.33	82.31±0.02	87.41±0.02	88.15±0.01
NBPN	73.44±0.31	85.52±0.08	89.05±0.08	89.71±0.19
TAMPN	82.40±0.35	85.64±0.24	88.71±0.09	89.70±0.03
TBPN	83.08±0.35	86.84±0.25	89.47±0.11	90.57±0.06




图 8 分类准确率

Fig. 8 Classification accuracy

中诊断精度也获得了相应的提升。在 5-shot 任务中,准确率分别提升了 3.14% 和 8.09%。通过对比 MerNet 和 NBPN 在各个任务中的表现,可以看出本文所提的近邻边界损失在各个任务中均获得了更好的效果,各个任务中分别提升了 4.95%、3.21%、1.64%、1.56%。结果表明,本文所提的损失通过调整类内和类间距离,能够获得更好的度量结果,提升了模型的故障诊断准确率。

由表 2 和图 8 可知,本文方法同时融合了时序注意力和近邻边界损失,取得了最高的故障诊断准确率。TBPN 针对振动信号的时序特性,利用时序注意力提升了原型网络的故障特征提取能力;同时针对度量空间中的样本分布问题,利用近邻边界损失修正了样本的空间

基于损失改进的 MerNet 和 NBPN 方法,在各个任务

分布,明确了原型表征边界。

为了更进一步的观察本文所提模型在各个类别故障中的表现,本文绘制了 20-shot 任务下的分类混淆矩阵,如图 9 所示。可以看出,所有故障识别率均在 80%以上,标签 3 齿轮根部故障可以被模型准确识别;标签 5 和标签 7 的齿轮断齿和齿轮缺齿故障,故障特征相似,但模型也可以做到高精度的识别;标签 0 和标签 1 均位于轴承的内外圈上,故障特征难以区分,误判率相较于其他几类略高,但是模型依旧可以做到很好的识别。




图 9 预测结果混淆矩阵

Fig. 9 Confusion matrix for prediction results

最后,为了直观的得到不同方法的分类表现,本文对不同方法在 20-shot 任务中,绘制了测试样本特征在度量空间中的 t-SNE 降维可视化,如图 10 所示。由图 10 可以看出,原型网络由于自身的特性,故障特征分布具有明显的聚类现象,但难分样本依旧存在混淆堆叠的现象;基于注意力的原型网络,由于能够通过注意力机制获得更好的故障特征,因此特征分布具有更好的聚类效果;基于损失的度量元学习网络,由于更好的调整了类内方差,使得各个故障类别的分布更加聚集。但是,对于一些难分类别,例如对于图中的 B1 和 B2 故障类型,以及 G2、G3 和 G4 故障类别,上述方法均有着明显混叠,模型无法很好分离各个类型故障的特征,模型识别精度无法进一步的提升。从图 10 中可以看出,本文所提方法可以很好的调整特征的空间分布,类内间距更加集中而类间间距更加分离,即便对难分类别也有着明显的分离作用,各个故障类型的特征有着最好的聚类分布。

5 结 论

本文提出了一种时序注意力边界增强原型网络用于小样本条件下的齿轮箱故障诊断。通过构建一种时序注意力,用来学习振动信号的时间序列特征,以获得更具判别性的故障特征。在原型网络的度量空间中引入近邻边界损失来调整特征分布,以获得更清晰的原型表示边




图 10 t-SNE 可视化

Fig. 10 Visualization obtained by t-SNE

界。本文所提方法利用近邻边界损失和时序注意力,在小样本条件下实现了良好的故障诊断性能。

实验结果表明,本文提出的方法故障诊断准确率最高,在4种不同样本条件下分别为83.08%、86.84%、89.47%和90.27%。与其他方法相比,本文能够更好地拟合数据总体分布,明确了原型表示边界,进一步提高了小样本条件下齿轮箱故障诊断的性能。

参考文献

- [1] WANG D, TSE P W, TSUI K L. An enhanced kurtogram method for fault diagnosis of rolling element bearings[J]. *Mechanical Systems and Signal Processing*, 2013, 35(1):176-199.
- [2] LI C, LI S, ZHANG A. Meta-learning for few-shot bearing fault diagnosis under complex working conditions [J]. *Neurocomputing*, 2021, 197-211.
- [3] WANG H, XU J, SUN C, et al. Intelligent fault diagnosis for planetary gearbox using time-frequency representation and deep reinforcement learning [J]. *IEEE/ASME Transactions on Mechatronics*, 2022, 27(2):985-998.
- [4] 赵小强,罗维兰.改进卷积Lenet-5神经网络的轴承故障诊断方法[J]. *电子测量与仪器学报*, 2022, 36(6): 113-125.
ZHAO X Q, LUO W L. Improved convolutional Lenet-5 neural network for bearing fault diagnosis[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(6): 113-125.
- [5] LU C, WANG Z, QIN W, et al. Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification[J]. *Signal Processing*, 2017, 130: 377-388.
- [6] ZHAO M, TANG B, DENG L, et al. Multiple wavelet regularized deep residual networks for fault diagnosis[J]. *Measurement*, 2020, 152: 107331.
- [7] ZHANG A, LI S, CUI Y, et al. Limited data rolling bearing fault diagnosis with few-shot learning[J]. *IEEE Access*, 2019, 7:110895-110904.
- [8] 陈保家,陈学力,肖文荣,等.小样本下滚动轴承故障的多源域迁移诊断方法[J]. *电子测量与仪器学报*, 2022, 36(2):219-228.
CHEN B J, CHEN X L, XIAO W R, et al. Multi-source domain transfer diagnosis method for rolling bearing faults under small samples [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(2): 219-228.
- [9] LEE Y O, JO J, WANG J H. Application of deep neural network and generative adversarial network to industrial maintenance: A case study of induction motor fault detection[C]. *2017 IEEE International Conference on Big Data (Big Data)*, 2017:3248-3253.
- [10] HUANG K, WU S, SUN B, et al. Metric learning-based fault diagnosis and anomaly detection for industrial data with intraclass variance[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022:1-12.
- [11] CHAI Z, ZHAO C. A fine-grained adversarial network method for cross-domain industrial fault diagnosis[J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 17(3): 1432-1442.
- [12] MAO W, DING Y LIU, DING L, et al. Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: A comparative study [J]. *IEEE Access* 7, 2019:9515-9530.
- [13] FENG Y, CHEN J, XIE J, et al. Meta-learning as a promising approach for few-shot cross-domain fault diagnosis: Algorithms, applications, and prospects[J]. *Knowledge-Based Systems*, 2022, 235: 107646.
- [14] SNELL J, SWERSKY K, ZEMEL R. Prototypical networks for few-shot learning[C]. *Advances in Neural Information Processing Systems*, 2017: 4080-4090.
- [15] JIANG C, CHEN H, XU Q, et al. Few-shot fault diagnosis of rotating machinery with two-branch prototypical networks [J]. *Journal of Intelligent Manufacturing*, 2022: 1-15.
- [16] SUN H, WANG C, CAO X. An adaptive anti-noise gear fault diagnosis method based on attention residual prototypical network under limited samples[J]. *Applied Soft Computing*, 2022, 125:109120.
- [17] HAN Y, TANG B, DENG L. An enhanced convolutional neural network with enlarged receptive fields for fault diagnosis of planetary gearboxes [J]. *Computers in Industry*, 2019, 107: 50-58.
- [18] QIN A, HU Q, LV Y, et al. Concurrent fault diagnosis, based on Bayesian discriminating analysis and time series analysis with dimensionless parameters [J]. *IEEE Sensors Journal*, 2019, 19(6):2254-2265.
- [19] XU H, ZHANG K, TIAN Y, et al. Overview of deep neural network image description [J]. *J Comput Eng Appl*, 2015:1-15.
- [20] WANG C, SUN H, CAO X. Construction of the efficient attention prototypical net based on the time-frequency characterization of vibration signals under noisy small sample[J]. *Measurement*, 2021, 179:109412.

作者简介



韩延, 2012 年于重庆大学获得学士学位, 2015 年于重庆大学获得硕士学位, 2020 年于重庆大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为装备智能运维、深度学习、边缘计算等。

E-mail: hanyan@cqupt.edu.cn

Han Yan received the B. Sc. degree, M. Sc. degree and Ph. D. degree from Chongqing University in 2012, 2015 and 2020, respectively. He is currently a lecturer at Chongqing University of Posts and Telecommunications. His main research interests include equipment intelligent operation and maintenance, deep learning and edge computing.



黄庆卿 (通信作者), 2009 年于重庆大学获得学士学位, 2015 年于重庆大学获得博士学位, 现为重庆邮电大学副教授, 主要研究方向为工业物联网、边缘计算、机械故障预测与健康管理的。

E-mail: huangqq@cqupt.edu.cn

Huang Qingqing (Corresponding author) received the Ph. D. degree in mechatronic engineering from Chongqing University. He is currently an associate professor at Chongqing University of Posts and Telecommunications. His main research interests include industrial internet of things, edge computing, and prognostics and health management of machine.