

DOI: 10.19650/j.cnki.cjsi. J2311201

噪声标签下注意力特征混合的旋转机械故障诊断^{*}

陈仁祥¹, 张旭¹, 徐向阳¹, 杨宝军², 赵玲¹, 何家乐¹

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室 重庆 400074; 2. 重庆智能机器人研究院 重庆 400714)

摘要:实际工程中,受人为标记或数据预处理等原因影响,旋转机械故障数据集易出现噪声标签,导致故障诊断模型性能降低,故提出注意力特征混合的旋转机械故障诊断方法。首先,构建残差神经网络(ResNet)提取样本中的时频特征,通过随机分组和特征交互构建正确标签样本组、部分噪声标签样本组和噪声标签样本组;其次,引入注意力机制计算各样本组内样本相关性对各组样本分配权值,得到能区分部分噪声样本组中噪声标签样本的差异性权值;然后,根据权值对每组样本进行混合(Mixup),通过对噪声标签样本插值并在反向传播中更新注意力层参数降低噪声标签样本所占比例;最后,利用在线标签平滑(OLS)统计模型预测信息更新软标签,通过降低噪声标签样本对模型损失更新的影响,进一步抑制噪声标签样本组的负面影响。在不同程度的噪声标签干扰下的旋转机械故障数据集上进行实验验证,检测精度均达到95%以上,证明了所提方法的有效性。

关键词: 旋转机械;故障诊断;噪声标签;注意力机制;在线标签平滑

中图分类号: TH165⁺. 3 TP18 **文献标识码:** A **国家标准学科分类代码:** 510.40

Fault diagnosis of rotating machinery with attentive feature mixup in noisy labels

Chen Renxiang¹, Zhang Xu¹, Xu Xiangyang¹, Yang Baojun², Zhao Ling¹, He Jiale¹

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Robotics Institute, Chongqing 400714, China)

Abstract: In practical engineering, the rotating machinery fault data set is prone to noise labels due to human labeling or data pre-processing, which could lead to the degradation of fault diagnosis model performance. Therefore, the attentive feature Mixup method of rotating machinery fault diagnosis is proposed. First, a residual neural network (ResNet) is established to extract time-frequency features from the samples. The correct label sample groups, partially noisy label sample groups, and noisy label sample groups are constructed through random grouping and feature interaction. Secondly, an attention mechanism is introduced to calculate the correlation between samples within each sample group, and assign weights to each group of samples. The different weights that can distinguish noisy label samples within partially noisy sample groups are achieved. Then, Mixup is performed on each group of samples according to their weights, which can interpolate noisy label samples and update the attention layer parameters during backpropagation to reduce the proportion of noisy label samples. Finally, the online label smoothing (OLS) is used to update the model's prediction information by reducing the negative impact of noisy label samples on the model loss update and further suppressing the effects of noisy label sample groups. Experiments on the rotating machinery fault dataset with label noise interference show the effectiveness of the proposed method.

Keywords: rotating machinery; fault diagnosis; noisy labels; attention mechanism; online label smoothing

收稿日期: 2023-03-21 Received Date: 2023-03-21

^{*} 基金项目: 国家自然科学基金(51975079/62073051)、重庆市教委科学技术研究项目(KJZD-M202200701)、重庆市自然科学基金创新发展联合基金(2023NSCQ-LZX0124)、重庆市研究生联合培养基地项目(JDLHPYJD2021007)、重庆市专业学位研究生教学案例库(JDALK2022007)、重庆交通大学研究生科研创新项目(2023S0072)资助

0 引言

旋转机械广泛应用于风力发电、工业机器人和航空航天等领域^[1],其在高速、重载等环境中长期服役,难免出现性能衰退甚至故障,导致严重安全事故。因此,有必要对旋转机械进行故障诊断。

近年来,基于数据驱动的监督学习方法在旋转机械故障诊断领域取得了显著成果,利用卷积神经网络^[2]及其改进网络^[3-5]实现了旋转机械故障诊断。而在工程实际样本标记时,受经验、主观和记录不当等影响,易造成对样本错误标记;同时,通信传输、数据处理过程中程序错误也会产生噪声标签^[6]。手动清理噪声标签数据是一种昂贵且耗时的解决方案,在实际工程中实施难度相当大。因此,提高故障诊断模型在含有噪声标签数据集上的性能显得尤为重要。

针对噪声标签问题,在模型中添加 Dropout^[7]和批归一化层^[8]收效甚微。为提高模型在噪声标签下的鲁棒性,国内外各学者开展了初步研究。Nie 等^[9]在归一化递归神经网络中引入前向交叉熵损失函数抑制噪声标签对网络的影响。王晓波等^[10]通过对损失函数加权以提高模型的鲁棒性。Wang 等^[11]提出一种多级对抗损失函数,使模型从标签噪声的数据集中构造出正确标签分布。Kim 等^[12]在训练过程中引入互补样本信息,将模型训练为“输入样本不属于这个补充标签”以此提高模型的泛

化性。噪声标签样本与正确标签样本之间的关系是处理噪声样本的关键^[13],上述方法忽略了样本间比较,独立地估计每个样本在训练过程中的权重。而通过样本间比较可促使模型学习特征分布关系,在考虑样本自身特征的同时更加关注与同类别样本的相似性,从而减少噪声标签样本干扰。

基于此,提出噪声标签下注意力特征混合的旋转机械故障诊断方法。首先,构建残差神经网络(residual neural networks, ResNet)提取时频样本中深层特征,通过随机分组和特征交互构建正确标签样本组、部分噪声标签样本组和噪声标签样本组;其次,利用注意力机制对每组内样本动态加权,得到能区分部分噪声样本组中噪声标签样本的差异性权值;然后,根据权值对每组内样本进行 Mixup,通过插值增加样本多样性并在反向传播中动态更新注意力层参数以降低噪声标签样本比例;最后,利用在线标签平滑(online label smoothing, OLS)统计模型预测信息更新类别软标签,增加判别故障类别信息量进一步抑制噪声标签样本组负面影响。实验表明所提方法在含有噪声标签场景下具有良好性能。

1 算法原理

所提出注意力特征混合的旋转机械故障诊断方法主要包括特征提取、注意力特征混合和在线标签平滑,整体结构如图1所示。




图1 网络整体结构

Fig. 1 Network architecture

1.1 特征提取

残差神经网络^[14]是一种改进卷积神经网络,通过在神经网络中引入残差模块能有效缓解因模型层数增加而导致神经网络性能下降的问题。残差块主要由卷积层和跳跃连接组成,残差神经网络中浅层学习的信息可以通过跳跃连接流向神经网络模型更深层,这使得神经网络模型可以构建更深层数,而不影响网络训练时的梯度计算。其定义如下:

$$H(\mathbf{x}) = F(\mathbf{x}) + \mathbf{x} \quad (1)$$

式中: $\mathbf{x}$ 是残差块输入, $F(\mathbf{x})$ 是残差函数, $H(\mathbf{x})$ 是恒等映射函数。

1.2 注意力特征混合

注意力特征混合(attentionive feature mixup, AFM)包括权重估计和 Mixup 两部分,这两部分都只在训练阶段进行处理。

1) 权重估计

将一个批量的样本经过残差神经网络提取特征得到 $\mathbf{x}_1, \dots, \mathbf{x}_n$, 随机选取 K 个特征进行组合;同时,使用 2 个全

连接层对特征进行映射降维;将特征交互构建的融合特征输入注意力模块,得到每组 K 个权重。其中 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的线性映射为:

$$\mathbf{u}_i = f_a(\mathbf{x}_i; \mathbf{w}_a) \quad (2)$$

$$\mathbf{u}_j = f_b(\mathbf{x}_j; \mathbf{w}_b) \quad (3)$$

式中: $\mathbf{w}_a$ 和 $\mathbf{w}_b$ 分别为全连接层 f_a 和 f_b 的参数,且 $f_a \neq f_b$ 。通过特征交互促使模型学习特征分布关系,在考虑样本自身特征的同时更加关注与同类别样本的相似性,因此对于交互后的特征其输出的 K 个权重中正确标签的权重会高于噪声标签的权重。其定义如下:

$$[\alpha_i^k, \alpha_j^k] = \Psi_i(\mathbf{u}_i \oplus \mathbf{u}_j; \boldsymbol{\theta}_i) = \Psi_i(f_a(\mathbf{x}_i; \mathbf{w}_a) \oplus f_b(\mathbf{x}_j; \mathbf{w}_b); \boldsymbol{\theta}_i) \quad (4)$$

其中, $\oplus$ 表示特征相加的交互形式, Ψ_i 是注意力模块, $\boldsymbol{\theta}_i$ 是其参数,其结构由 FC-FC-ReLu-Sigmoid 组成,采用两层全连接层实现非线性,并在 Sigmoid 输出之前添加 ReLu 保证权重 α 在 $[0.5, 1]$ 之间, k 表示第 k 组。

2) Mixup

Mixup 将权重 $[\alpha_i, \alpha_j]$ 按比例对同组样本特征 $(\mathbf{x}_i, \mathbf{x}_j)$ 进行混合,得到新特征 $\mathbf{x}'$, 具体计算过程如下所示:

$$\mathbf{x}' = \alpha_i^k \mathbf{x}_i + \alpha_j^k \mathbf{x}_j \quad (5)$$

$$\mathbf{y}' = \alpha_i^k \mathbf{y}_i + \alpha_j^k \mathbf{y}_j \quad (6)$$

通过注意力特征混合模块不仅在类内而且在类间插值得到新样本,增加了插值的数量并扩大决策边界。由于特征混合而产生的局部噪声样本可以通过降低权重来减小其对模型输出的影响。如 $K=2$ 时,通过注意力特征混合模块可以得到 4 种情况(正确表示正确标签样本,错误表示噪声标签样本, $+$ 表示 Mixup 操作):

(1) 正确+正确 $\rightarrow$ 正确标记的样本;

(2) 类内: 正确+错误 $\rightarrow$ 部分噪声样本组(注意力机制抑制噪声标签样本的权重);

(3) 类间: 正确+错误 $\rightarrow$ 部分噪声样本组(注意力机制抑制噪声标签样本的权重);

(4) 错误+错误 $\rightarrow$ 噪声标签样本组。

N_{noisy} 和 N_{total} 分别表示噪声标签样本数量和总数据集数量,那么样本是噪声标签样本概率可以表示为:

$$p = \frac{N_{noisy}}{N_{total}} \quad (7)$$

通过上述分组结果可知,噪声标签样本组(错误+错误)的组合方式有 $A_{N_{noisy}}^2$ 种,那么组合后概率为:

$$\frac{A_{N_{noisy}}^2}{A_{N_{total}}^2} = \frac{N_{noisy}(N_{noisy} - 1)}{N_{total}(N_{total} - 1)} \approx \frac{N_{noisy}^2}{N_{total}^2} \quad (8)$$

上述结果可知:

$$\frac{N_{noisy}}{N_{total}} > \frac{N_{noisy}^2}{N_{total}^2} \quad (9)$$

经排列组合后,噪声标签样本组的比例显著减少。

1.3 在线标签平滑

尽管注意力特征混合模块能够抑制噪声标签的影响,但直接将其应用于旋转机械故障诊断任务中仍存在着以下问题。因真实标签是独热码形式,混合生成标签向量 $\mathbf{y}'$ 最多有两个非零值,这种情况下通过最小化交叉熵训练诊断模型依然能拟合到噪声标签样本。因此在注意力特征混合的过程中引入在线标签平滑^[15]策略,通过在训练阶段类别相似性动态更新软标签,在目标类别和非目标类别之间构造合理的概率分布,以此降低噪声标签的负面影响。

定义 $\mathbf{S} = \{\mathbf{S}^0, \mathbf{S}^1, \dots, \mathbf{S}^t, \mathbf{S}^{T-1}\}$ 表示不同训练阶段类级软标签集合, T 表示迭代轮数, $\mathbf{S}^t$ 是 M 行 M 列的矩阵, M 为故障类别数目,其每一列对应一个故障类别的软标签。对于 Mixup 插值特征 $\mathbf{x}'$ 的训练损失公式如下:

$$L_{soft} = - \sum_{m=1}^M \mathbf{S}_{y',m}^{t-1} \times \log p(l|\mathbf{x}') \quad (10)$$

式中: $\mathbf{S}_{y',m}^{t-1}$ 表示其中示目标类别 $\mathbf{y}'$ 的软标签, $m \in \{1, \dots, M\}$ 。因此训练总损失如下:

$$L_{total} = \alpha L_{hard} + (1 - \alpha) L_{soft} \quad (11)$$

式中: L_{hard} 表示用硬标签训练损失, α 用于平衡 L_{hard} 和 L_{soft} 。

在第 t 个训练迭代中,使用输入样本的预测概率监督 $t+1$ 次迭代的模型训练。第 t 个训练迭代开始时,软标签 $\mathbf{S}^t$ 初始化为零矩阵,当模型对输入样本正确分类时,利用其预测概率 $p(\mathbf{x}_i)$ 更新 $\mathbf{S}^t$ 中 $\mathbf{y}_i$ 列,具体计算过程如下:

$$\mathbf{S}_{y_i,m}^t = \mathbf{S}_{y_i,m}^{t-1} + p(l|\mathbf{x}_i) \quad (12)$$

式中: $p(l|\mathbf{x}_i)$ 表示模型预测概率。在第 t 次迭代结束后,可以得到 M 类标准化软标签 $\mathbf{S}^t$, 用于监督模型下一个训练阶段。式(10)表明所有正确分类样本都会对当前训练样本施加类内约束。这些约束使同一类样本更加接近,决策边界附近的样本数量将减少,进一步抑制噪声标签样本影响。

2 注意力特征混合的故障诊断流程

如图 2 所示,注意力特征混合的旋转机械故障诊断流程如下:

1) 首先利用连续小波变换(continuous wavelet transform, CWT)对振动信号进行变换得到时频图;

2) 构造 ResNet, 初始化网络参数和类级软标签;

3) 以批量方式将训练集输入网络得到输出特征,并随机选取特征进行分组及特征交互;

4) 利用注意力机制估计每组中特征的权值,通过权值的差异区分每组中的噪声标签样本特征;

5) 利用 Mixup 对特征进行加权混合,通过插值增加样本的多样性,降低噪声标签样本比例;

- 6) 根据模型输出信息更新类级软标签;
- 7) 利用式(7)计算损失,并反向传播更新网络参数,同时降低噪声标签的权重;
- 8) 重复步骤3)~7),直到迭代次数达到设定值,并保存网络模型;
- 9) 输入测试样本得到诊断结果。




图2 方法流程
Fig. 2 Flow chart of method

3 实验分析

3.1 实验数据

如图3所示,采用加速度传感器采集 LHSG-17-80 谐波减速器振动信号,采样频率为 10 240 Hz,采样长度 1 000 k。谐波减速器状态分别为间隙过大、卡顿和正常。其中间隙过大的减速器由于传动部件之间的啮合不紧密,导致设备的稳定性降低,传动时会出现明显的振动。而卡顿的减速器由于转动时会出现卡塞,导致运动过程不流畅,设备输出速度下降。



图3 谐波减速器状态及传感器安装位置
Fig. 3 Harmonic reducer status and sensor location

实验分别在 30% 和 60% 转速工况下采集工业机器人末端关节上下往复运动多组数据,按照 8:2 划分训练集和测试集。通过连续小波变换得到时频样本如图 4 所示。观察时频图可知,3 种不同状态的谐波减速器振动信号能量整个时间段呈现明显能量波动,低频段相对于高频段能量较高,且间隙过大整体能量范围明显大于另外两类减速器。




图4 小波时频图
Fig. 4 Wavelet time-frequency diagram

为保证模型在含噪声标签样本数据集中有效地学习正确标签样本特征,标签噪声率 (label noise rate, LNR) 需要满足以下条件。如果 LNR 接近上界,在实际中很难成功训练。

$$LNR < \frac{M - 1}{M}$$

(13)

其中, M 为故障类别数目。随机对每一类数据样本的标签翻转,在每类的数据中引入 10%、20%、30% 和 40% 的随机噪声标签,噪声标签由其他两类标签组成。

3.2 实验结果及分析

采用 ResNet 作为主干网络提取样本深层特征,优化器使用随机梯度下降算法,初始学习率设置为 0.01,采用等间隔调整学习率策略,调整间隔为 13 轮,衰减倍率为 0.1,批量大小为 64,迭代轮数为 50 轮。以下实验均在 Windows10 系统环境下,使用显存为 6 G 的 NVIDIA GeForce RTX3060 显卡上进行。

将所提方法与 ResNet、文献[10]方法、文献[11]方法及文献[12]方法分别在 $LNR = 0\%$ 、 10% 、 20% 、 30% 和 40% 下进行对比。表 1 为 60% 运行工况下不同方法在不同标签噪声率下最后 5 轮平均准确率,图 5 为 60% 运行工况 $LNR = 40\%$ 时不同方法分类准确率。

表 1 不同方法准确率对比

Table 1 The accuracy of different methods %					
方法	标签噪声率				
	0	10	20	30	40
ResNet	100	94.64	81.01	79.97	69.13
文献[10]	100	98.70	97.83	90.44	79.13
文献[11]	100	98.84	96.81	90.58	83.19
文献[12]	100	100	98.55	96.23	91.45
所提方法	100	100	100	97.96	95.22




图 5 不同方法分类准确率对比

Fig. 5 Accuracy comparison of different methods

文献[10]方法在 26 轮识别准确率收敛于 78% 左右,相比 ResNet 具有一定噪声标签鲁棒性,但其损失函数中的交叉熵依然会拟合噪声标签;文献[11]方法在 28 轮收敛于 83.33% ,该方法在模型不同迭代阶段使用不同损失函数以提供正则化约束,相比文献[10]方法能有效地学习到正确标签分布,但该方法确定模型拟合噪声标签的阶段依赖实验测试,不利于工程应用。

文献[12]方法通过在 ResNet 中引入互补标签缓解噪声标签样本负面影响,在不同标签噪声率下的准确率均有提升。但该方法随着 LNR 增大,越难以构建正确标签分布,导致诊断精度下降;所提方法在 21 轮左右稳定收敛在 95.22% 左右,且在不同标签噪声率下均有较高的准确率。这是因为所提方法一方面通过注意力特征混合模块对 ResNet 提取的特征进行插值,通过增加样本多样性以降低噪声标签样本比例;另一方面,通过训练阶段类别相似性动态更新软标签,进一步抑制了噪声标签样本的负面影响。

为证明所提方法抑制噪声标签样本权重的作用。输出 $LNR = 40\%$ 时组内样本权重,如表 2 所示。权重 a_1 和

b_1 表示未更新权重,权重 a_2 和 b_2 表示更新后权重。由表 2 可知,正确标签样本相互组合和噪声标签样本相互组合输出权重都趋于 0.5 左右,因为这些特征位于决策边界附近;对于正确标签样本与噪声标签样本组合的情况,所提方法有效的降低了噪声标签样本权重。

表 2 不同组合情况下的权重

Table 2 Weights in different combinations				
Mixup	权重 a_1	权重 b_1	权重 a_2	权重 b_2
类内	正确+正确	0.466 2	0.533 8	0.535 5
	正确+错误	0.513 6	0.486 4	0.635 5
类间	错误+错误	0.502 5	0.497 5	0.530 9
	正确+正确	0.518 0	0.482 0	0.547 6
类间	正确+错误	0.530 5	0.469 5	0.633 0
	错误+错误	0.536 1	0.463 9	0.518 2

为证明所提方法能降低噪声标签样本组比例,分别在标签噪声率等于 10% 、 20% 、 30% 和 40% 下统计噪声标签样本组的比例。如表 3 所示,样本通过注意力特征混合模块后,噪声标签样本组比例与式(8)计算的理论值相近,相比于原标签噪声率明显降低。

表 3 噪声标签样本组比例

Table 3 Ratio of noisy label sample groups %		
标签噪声率	理论值	真实值
10	1.0	1.0
20	4.0	4.7
30	9.0	9.4
40	16.0	14.5

为分析所提方法中 AFM 和 OLS 的有效性,对原主干网络是否使用这两部分进行消融实验($LNR = 40\%$)。如表 4 所示,分别添加 AFM 和 OLS 模块,诊断精度分别提高了 16.96% 和 5.36% 。同时使用 AFM 和 OLS,诊断精度提高了 26.09% 。证明了所提方法能够提高模型在含有噪声标签样本数据集上的诊断性能。

同时为展示所提方法在噪声标签样本干扰下的特征提取能力,引入 t-SNE 可视化测试集特征分布。利用 k 均值聚类算法计算隶属度矩阵,同时使用划分系数(partition coefficient, PC)和划分熵(partition entropy, PE)评估特征聚集效果,其定义如下:

$$PC = \sum_{i=1}^n \sum_{m=1}^M \frac{u_{mi}^2}{n}$$

(14)

$$PE = - \sum_{i=1}^n \sum_{m=1}^M \frac{u_{mi} \times \log(u_{mi})}{n}$$

(15)

表 4 不同模块的消融实验对比

Table 4 Comparison of ablation experiments of different modules			%
AFM	OLS	准确率	提升
×	×	69.13	—
✓	×	86.09	16.96 ↑
×	✓	74.49	5.36 ↑
✓	✓	95.22	26.09 ↑

其中, M 表示故障类别数, u_{mi} 表示第 i 个样本属于第 m 类故障的隶属度, n 为总样本数, PC 表示样本的平均隶属度, PE 表示给定样本的分类方案的不确定性。 PC 越大, PE 越小, 则特征聚集效果越好。

如图 6 所示, ResNet 和文献 [10] 方法完全不能区分 3 种故障状态, 重叠部分较多。文献 [11-12] 和未添加 OLS 时在噪声标签干扰下提取的特征可使 3 种故障状态彼此区分, 但仍存在部分重叠。而所提方法通过 OLS 使得类内特征更紧密, 类间特征分离更明显, 且 PC 和 PE 处于较优状态, 分别为 0.87 和 0.24。证明了所提方法在标签噪声干扰下依然能学到良好的特征表示。




图 6 特征可视化效果图
Fig. 6 Feature visualization rendering

为验证所提方法的泛化能力, 选用 30% 工况下谐波减速器故障数据进行验证。表 5 表示不同方法准确率, 图 7 表示 $LNR = 40\%$ 时不同方法准确率曲线。由表 5、图 7 可知, 所提方法在各标签噪声率下均具有较高的准确率。 $LNR = 40\%$ 时, 所提方法在 32 轮准确率达到了

表 5 30% 工况下不同方法准确率对比

Table 5 Accuracy comparison of different methods under 30% working conditions						%
方法	标签噪声率					
	0	10	20	30	40	
ResNet	100	88.15	89.63	73.33	62.59	
文献[10]	100	100	92.59	87.41	64.44	
文献[11]	100	98.15	92.22	85.19	68.52	
文献[12]	100	96.67	93.33	85.56	86.67	
所提方法	100	100	96.30	94.44	92.59	




图 7 不同方法分类准确率对比
Fig. 7 Accuracy comparison of different methods

92.59%, 而 ResNet、文献 [10] 和文献 [11] 方法都在 70% 以下, 文献 [12] 方法准确率仅为 87.04%。所提方法在 30% 工况下的含噪声标签样本故障数据集依然具有较高准确率, 证明了所提方法的泛化能力。

4 结 论

针对噪声标签导致模型诊断性能下降的问题,提出了注意力特征混合的旋转机械故障诊断方法。通过随机分组和特征交互构建了正确标签样本组、部分噪声标签样本组和噪声标签样本组。利用注意力机制对每组内样本分配权重,得到了能区分部分噪声标签样本组中噪声标签样本的差异性权值,并根据权值对每组样本进行 Mixup,通过插值增加样本多样性降低了噪声标签样本比例;然后,利用 OLS 统计模型预测信息更新软标签,增加判别故障类别信息量进一步抑制了噪声标签样本组的影响。但所提方法并不能解决所有噪声标签水平下的故障诊断问题,同时若数据集中噪声标签的分布与正确标签分布相似,会对故障诊断任务准确性产生负面影响。需进一步研究和改进方法,以提高故障诊断任务的准确性。

参考文献

- [1] 李涛,段礼祥,张东宁,等. 自适应卷积神经网络在旋转机械故障诊断中的应用[J]. 振动与冲击, 2020, 39(16): 275-282,288.
- LI T, DUAN L X, ZHANG D N, et al. Application of adaptive convolutional neural network in rotating machinery fault diagnosis[J]. Journal of Vibration and Shock, 2020, 39(16): 275-282,288.
- [2] 陈仁祥,张勇,杨黎霞,等. 基于整周期数据和卷积神经网络的谐波减速器健康状态评估[J]. 仪器仪表学报, 2020, 41(2): 245-252.
- CHEN R X, ZHANG Y, YANG L X, et al. Health condition assessment of harmonic reducer based on integer-period data and convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(2): 245-252.
- [3] 徐卓飞,李旭东,张婵婵,等. 基于孪生网络的小样本滚动轴承故障诊断研究[J]. 仪器仪表学报, 2023, 43(10): 241-251.
- XU ZH F, LI X D, ZHANG CH CH, et al. Fault diagnosis of rolling bearings with limited samples based on siamese network[J]. Chinese Journal of Scientific Instrument, 2023, 43(10): 241-251.
- [4] 王鸽,吴国新,刘秀丽. 基于 MADCNN 的故障诊断方法研究[J]. 电子测量与仪器学报, 2023, 37(3): 187-193.
- WANG G, WU G X, LIU X L. Research on fault diagnosis method based on MADCNN[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 187-193.
- [5] 韩延,李超,黄庆卿,等. 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[J]. 电子测量与仪器学报, 2023, 37(2): 90-98.
- HAN Y, LI CH, HUANG Q Q, et al. Boundary-enhanced prototype network with time-series attention for gearbox fault diagnosis under limited samples[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 90-98.
- [6] 张旭,黄亦翔,张轩,等. 基于改进堆栈自编码的诊断错误标签修正[J]. 振动与冲击, 2022, 41(1): 78-87.
- ZHANG X, HUANG Y X, ZHANG X, et al. Diagnostic noise label correction based on improved stacked auto-encoder[J]. Journal of Vibration and Shock, 2022, 41(1): 78-87.
- [7] 侯召国,王华伟,周良,等. 基于改进深度残差网络的谐波减速器故障诊断[J]. 系统工程与电子技术, 2022, 44(6): 2051-2059.
- HOU ZH G, WANG H W, ZHOU L, et al. Fault diagnosis of rotating machinery based on improved deep residual network[J]. Systems Engineering and Electronics, 2022, 44(6): 2051-2059.
- [8] 冯浩楠,付胜,胥永刚. 基于 BN-1DCNN 的旋转机械故障诊断研究[J]. 振动与冲击, 2021, 40(19): 302-308.
- FENG H N, FU SH, XU Y G. Fault diagnosis of rotating machinery based on BN-1DCNN model[J]. Journal of Vibration and Shock, 2021, 40(19): 302-308.
- [9] NIE X, XIE G. A novel normalized recurrent neural network for fault diagnosis with noisy labels[J]. Journal of Intelligent Manufacturing, 2021, 32(5): 1271-1288.
- [10] 王晓波,尹俊平,徐岩. 基于鲁棒损失函数的标签有噪信号调制方式识别[J]. 计算物理, 2022, 39(4): 386-394.
- WANG X B, YIN J P, XU Y. Robust loss functions for signal modulation recognition with noise labels[J]. Chinese Journal of Computational Physics, 2022,

39(4): 386-394.

[11] WANG H, LI Y F. Robust mechanical fault diagnosis with noisy label based on multistage true label distribution learning[J]. IEEE Transactions on Reliability, 2022: 1-14.

[12] KIM Y, YIM J, YUN J, et al. Nlnl: Negative learning for noisy labels [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 101-110.

[13] PENG X, WANG K, ZENG Z, et al. Suppressing mislabeled data via grouping and self-attention [C]. European Conference on Computer Vision. Springer, Cham, 2020: 786-802.

[14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

[15] ZHANG C B, JIANG P T, HOU Q, et al. Delving deep into label smoothing[J]. IEEE Transactions on Image Processing, 2021, 30: 5984-5996.

作者简介



陈仁祥(通信作者),分别在 2007 年和 2012 年于重庆大学获得学士学位和博士学位,现为重庆交通大学教授、博士生导师,主要研究方向为智能测试技术与信号处理。
E-mail:manlou.yue@126.com

Chen Renxiang (Corresponding author) received his B. Sc. and Ph. D. degrees both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and a Ph. D. advisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



张旭,2021 年于重庆交通大学获得学士学位,现为重庆交通大学硕士研究生,主要研究方向为机电装备故障诊断。
E-mail: 599523514@qq.com

Zhang Xu received his B. Sc. degree from Chongqing Jiaotong University in 2021. He is currently a master student at Chongqing Jiaotong University. His main research interest is fault diagnosis.