

DOI: 10.19650/j.cnki.cjsi.J2513792

# 多源不平衡数据下基于联邦学习的谐波 减速器故障诊断方法<sup>\*</sup>

王玉静<sup>1</sup>, 叶柏宏<sup>1</sup>, 康守强<sup>1</sup>, 刘连胜<sup>2</sup>, 孙宇林<sup>1</sup>

(1. 哈尔滨理工大学黑龙江省模式识别与信息感知重点实验室 哈尔滨 150080;

2. 哈尔滨工业大学自动化测试与控制研究所 哈尔滨 150001)

**摘要:**针对工业机器人谐波减速器不同故障类别样本数量不平衡,以及单源信号获取信息往往有限,导致故障诊断准确率不高的问题,提出一种多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法。该方法通过对不同用户的多源信号做小波变换,将一维信号转换为二维图像,构建时频图数据集;利用改进的数据增强方法对不平衡数据集进行均衡处理;引入有效的通道注意力机制,并通过可学习的权重加权残差分支的输出,以增强模型对不同输入信号残差信息的适应性和对数据关键特征的提取能力;通过改进的多模态变分自编码器挖掘多源信号之间的互补信息进行特征融合,并采用焦点损失函数作为训练损失函数,使模型能够更关注错分频率较高的类别样本,构建多用户个性化本地模型;服务器端聚合用户本地模型参数并更新全局模型,通过联邦学习保障用户端本地的孤岛隐私数据,从而对多源不平衡数据下谐波减速器进行故障诊断。通过搭建谐波减速器信号采集实验平台进行验证,所提方法能够有效提取谐波减速器多源不平衡数据的特征并实现信息融合,平均故障诊断准确率为98.8%,性能优于所对比的方法。

**关键词:** 数据不平衡;多源信息融合;联邦学习;谐波减速器;故障诊断

**中图分类号:** TN911.7 TH165.3 **文献标识码:** A **国家标准学科分类代码:** 460.4099

## Fault diagnosis method for harmonic reducers based on federated learning with multi-source imbalanced data

Wang Yujing<sup>1</sup>, Ye Baihong<sup>1</sup>, Kang Shouqiang<sup>1</sup>, Liu Liansheng<sup>2</sup>, Sun Yulin<sup>1</sup>

(1. Heilongjiang Province Key Laboratory of Pattern Recognition and Information Perception, Harbin University of Science and Technology, Harbin 150080, China; 2. Automatic Test and Control Institute, Harbin Institute of Technology, Harbin 150001, China)

**Abstract:** Aiming at the problems of imbalanced sample sizes across different fault categories in industrial robot harmonic reducers and the limited information obtained from single-source signals, which result in low diagnostic accuracy, a fault diagnosis method for harmonic reducers is proposed based on federated learning under multi-source imbalanced data. This method performs wavelet transform on the multi-source signals of different users to convert one-dimensional signals into two-dimensional images, constructing a time-frequency dataset. An improved data augmentation method is then applied to balance the dataset. The efficient channel attention is introduced, and the output of the residual branches is weighted by learnable weights, which can enhance the model's adaptability to residual information of different input signals and the ability to extract key features of the data. A modified multimodal variational autoencoder is used to mine the complementary information among multi-source signals for feature fusion, and adopting the focal loss function as the training loss function, the model can pay more attention to category samples with high misclassification frequencies, thus constructing personalized local models for multi-user. The server aggregates the local model parameters at the multi-user and updates the global model, multi-user local island privacy data is protected through federated learning, so as to achieve the fault diagnosis of harmonic reducers under multi-source imbalanced data. The effectiveness of the proposed method is verified by building a signal acquisition

收稿日期: 2025-03-02 Received Date: 2025-03-02

<sup>\*</sup> 基金项目: 国家自然科学基金(52375533)、黑龙江省自然科学基金(PL2024E022)、山东省自然科学基金(ZR2023ME057)、哈尔滨市制造业科技创新人才(2023CXRC017)项目资助

experimental platform for harmonic reducers. The proposed method can effectively extract the features from multi-source imbalanced data of harmonic reducers and achieve information fusion, achieving an average fault diagnosis accuracy of 98.8%, outperforming the compared methods.

**Keywords:** data imbalance; multi-source information fusion; federated learning; harmonic reducer; fault diagnosis

## 0 引言

谐波减速器最初在航天设备的驱动部件得到广泛应用,随着技术的发展,其应用领域逐步扩展到机器人、光学设备和医疗器械等多个领域,其中,谐波减速器在工业机器人关节的应用最为普遍<sup>[1]</sup>。作为工业机器人的核心部件,谐波减速器拥有高减速比、传动比大和高传动精度等优势<sup>[2]</sup>。谐波减速器的故障风险高于常规减速器,若出现异常可能导致生产效率下降和意外停机,甚至生产线工人的生命安全亦将受到严重威胁<sup>[3]</sup>。由于谐波减速器长时间处于正常工作状态,故障数据较少,导致不同故障类型的数据不平衡,同时用户之间希望私有数据不共享,存在数据孤岛,并且单一传感器获取的信息往往有限,这使得谐波减速器的故障诊断变得更加困难。因此,在保障数据隐私的前提下对谐波减速器的多源不平衡数据进行故障诊断,具有重要的现实意义。

随着人工智能的发展,深度学习依靠卓越的特征提取能力,在谐波减速器等旋转机械故障诊断研究中展现出显著的应用价值<sup>[4]</sup>。文献[5]提出结合一维卷积神经网络和矩阵核的自适应模型,对卷积核尺度进行调整,提高对谐波减速器时域信号的特征提取能力。文献[6]设计一种多尺度混合卷积神经网络,从谐波减速器多通道信号中提取更加全面的故障特征。文献[7]为精准表征谐波减速器的运行状态信息,利用互相关法确定振动信号整周期数据起始位置,通过相位差频谱校正确定数据长度,在实际诊断过程中取得了良好效果。文献[8]提出连续 Morlet 小波变换与 Hilbert 频谱分析结合的故障特征提取方法,完成对谐波减速器柔性轴承的故障识别。文献[9]设计一种双路径卷积神经网络结合多通道混合注意力机制和双向门控循环单元,实现谐波减速器不同工况的有效诊断。

上述方法构建数据集时设定为各类别数据平衡。然而,实际情况中各类别数据往往是不平衡的,正常样本的数量比故障样本的数量大得多,对构建故障诊断模型造成影响<sup>[10]</sup>。因此,有必要解决因不平衡数据导致少数类样本故障诊断精度低的问题。文献[11]提出一种两步聚类算法,以增强用于不平衡数据的过采样技术算法,实现对滚动轴承的故障识别。文献[12]设计一种改进的生成对抗网络,应对数据不平衡问题,能够更好地对齿轮箱进行故障诊断。文献[13]提出基于频谱对齐和深度

传输卷积神经网络的新型故障诊断方法,用数据增强模块从不平衡轴承数据中提取特征,实验表明相比于其他方法取得了更优异的诊断结果。文献[14]构建高斯混合模型来获得样本的分布表示,从多数类中提取与原始样本集具有相似的分布的样本,用于建立平衡的标记样本集,所提方法能有效提高故障诊断率。上述研究在解决数据不平衡下故障诊断的问题是从单源数据的角度进行考虑。

然而,当处于现实工业情形时,由于传感器受本身物理特性及精度等因素制约,使用单一传感器采集的信息有限,通常难以涵盖设备工作过程中所有特征<sup>[15]</sup>。并且,检测谐波减速器时所采用的传感器因与工业机器人关节协同运动,可能造成单一传感器采集的信号在全面性与稳定性方面有所欠缺<sup>[16]</sup>。针对单一传感器在获取设备运行信息时存在局限性,易引发错误诊断的问题,采用多传感器协同作业的方式,能够更为全面地采集设备运行状态数据。因此,依靠多源数据理论上可有效减少故障诊断的不确定性<sup>[17]</sup>。近年来,在旋转机械故障诊断领域,多源信息融合方法已成为提升诊断准确率的重要技术<sup>[18]</sup>。文献[19]提出一种多传感器融合的谐波减速器故障诊断模型,显著提高了故障诊断准确率。文献[20]提出使用自回归模型提取振动信号的特征,然后通过级联神经网络完成数据融合。实验结果显示,相较于单传感器诊断,多传感器数据融合的诊断结果在准确性方面更为优异。文献[21]将谐波减速器多传感器的振动信号进行融合,通过子域适应方法实现不同工况下故障诊断。文献[22]提出一种耦合卷积残差网络来实现滚动轴承振动信号和声发射信号信息流融合,获得较好的诊断准确率。

当具备充足训练数据支撑时,深度学习方法在故障诊断领域能够取得良好的准确率。然而,受经济成本约束以及相关法律规制等因素影响,各工业用户在实际情况中普遍难以获取到充足的优质数据。同时,出于对数据安全的考虑,工业用户多倾向将数据留存在本地,由此衍生出数据孤岛现象以及数据隐私保护问题<sup>[23]</sup>。对于上述问题,基于深度学习的智能诊断技术存在一定的局限性。联邦学习是一种分布式训练框架,可以有效解决深度学习难以应对的数据孤岛与数据隐私保护问题<sup>[24]</sup>。文献[25]采用改进的轻量级网络 SqueezeNet 作为联邦框架用户端特征提取网络,降低模型训练时间,并提高往复机械故障诊断准确率。文献[26]提出用于多用户

混合故障诊断的联邦框架,将用户端网络划分为多个并行网络,更好地实现旋转机械故障诊断。上述研究利用联邦学习方法保护不同用户端数据隐私,并且通过改进本地用户端的特征提取网络更好地实现故障诊断,但没有考虑不同客户端个性化的问题。

针对实际情况中谐波减速器正常状态样本多,故障类别样本少,以及单源信号难以提供全面的故障信息,造成故障诊断准确率不理想的问题,提出一种多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法。该方法通过数据增强技术对不同用户多源不平衡数据进行处理,以降低数据的不平衡性;利用有效的通道注意力机制并动态加权残差网络的不同分支来强化网络对多源数据的特征提取能力;并通过多模态变分自编码器对多源数据特征进行融合,进一步提升故障诊断的精度,利用联邦学习保障孤岛数据隐私并对客户端进行个性化处理,构建故障诊断模型,从而有效实现多源不平衡数据下谐波减速器的故障诊断。

## 1 数据增强算法

### 1.1 Mixup 数据增强算法

Mixup 是一种数据增强算法<sup>[27]</sup>,最初提出的目的是通过减少过拟合来提高深度学习的性能。它依赖于通过将现有的训练样本及其相应的标签进行凸组合来组成新的合成样本,来减少深度神经网络中的过拟合。如果  $(x_i, y_i), (x_j, y_j)$  是由数据  $x_i, x_j$  和其相关的标签  $y_i, y_j$  组成的训练样例,则 Mixup 创建合成数据和标签如式(1)和(2)所示。

$$\hat{x} = \lambda x_i + (1 - \lambda) x_j \quad (1)$$

$$\hat{y} = \lambda y_i + (1 - \lambda) y_j \quad (2)$$

式中:  $\lambda \sim \beta(\theta, \theta)$  的  $\beta$  分布,且  $\theta > 0$ ;  $\hat{x}$  和  $\hat{y}$  是生成的新数据和标签。

### 1.2 Mixup 数据增强算法的改进

当面临数据不平衡时,多数智能诊断模型倾向于关注多数类样本,却忽略了少数类样本所蕴含的关键特征,此种情况显著影响模型判断不同故障的能力。在长尾分布中,直接使用 Mixup 可能会增加数据集的不平衡性,改进的采样策略可以用来减轻这种影响,数据采样策略如式(3)所示。

$$q_i = \frac{n_i^l}{\sum_{r=1}^R n_r^l} \quad (3)$$

式中:  $q_i$  表示从第  $i$  类中采样的概率;  $n_r$  表示第  $r$  类样本的数量;  $R$  为样本类别数。在这种情况下,选择  $l=1$  相当

于选择概率等于其类在训练集中出现频率的样本,而选择  $l=0$  则导致每个类的抽样概率为  $q_i = 1/R$ ,  $(x_i, y_i)$  和  $(x_j, y_j)$  分别从  $l=1$  和  $l=0$  两个概率空间选取。在新一轮训练的过程中,根据模型训练上一轮得到的数据增强结果,重新计算出新一轮不同类型样本的权重,通过这种方式使生成的样本空间更加平衡。

为了进一步提高模型在数据不平衡情况下故障诊断的能力,使用焦点损失函数替代原本的交叉熵损失函数作为模型分类损失函数,如式(4)所示。

$$L_{class} = - \sum_{i=1}^R \alpha (1 - p_i)^\gamma y_i \log(p_i) \quad (4)$$

式中:  $\alpha$  为平衡因子;  $\gamma$  为焦点因子;  $p_i$  表示预测为第  $i$  类的概率。焦点损失函数使模型更关注错分频率高的样本,以此提高模型的分类准确率,进一步解决数据不平衡的问题。

## 2 改进的残差网络

### 2.1 残差网络

随着深度学习技术的发展,网络变得更深,出现梯度消失与网络退化等问题。残差网络(residual network, ResNet)可以在一定程度上缓解这些问题<sup>[28]</sup>。残差块是 ResNet 的基本架构,通过输入  $x$  的恒等映射与卷积层提取的特征  $F(x)$  相加,得到残差块输出  $M(x)$ ,如图1所示。




图1 残差块基本结构

Fig. 1 Basic structure diagram of residual block

### 2.2 残差网络的改进

为了提高残差网络的性能,引入一种有效的通道注意力模块(efficient channel attention, ECA)<sup>[29]</sup>。ECA 模块可以有效地增加卷积神经网络的表达能力,避免通道降维导致的信息损失,同时减少计算量和参数数量。ECA 模块的运行过程是对输入数据  $X(C, H, W)$  进行全局平均池化(global average pooling, GAP),使输入特征维持通道数不变,然后进行卷积核大小为  $k$  的一维卷积计算,得到输出特征  $Y(C, H, W)$ ,其运行过程示意图如图2所示。






图2 ECA模块示意图

Fig. 2 Schematic diagram of ECA module

图2中 $H$ 为特征图高度, $W$ 为特征图宽度, $k$ 的计算方式如式(5)所示。

$$k = \Psi(C) = \left\lfloor \frac{\log_2 C}{\tau} + \frac{\zeta}{\tau} \right\rfloor_{Odd} \quad (5)$$

式中: $\Psi$ 为映射关系; $C$ 为通道数; $\tau$ 为2; $\zeta$ 为1; $Odd$ 为离结果最近的奇数值。

ResNet的残差块输出如式(6)所示。

$$M(x) = F(x) + x \quad (6)$$

残差块的输出是将卷积层提取的特征 $F(x)$ 和原始输入 $x$ 相加,有助于缓解诸如梯度消失之类的问题,从而更有效地训练深度模型。然而,卷积层提取的特征和原始输入对模型训练的影响力可能不相等。为了控制每个分量的影响,在输入和卷积层提取的特征之间引入一个可学习的权重。如式(7)所示。

$$M(x) = F(x) + \mu x \quad (7)$$

式中: $\mu$ 是调节输入数据影响力的权重。

### 3 联邦学习

#### 3.1 联邦学习框架

联邦学习(federated learning, FL)作为集中式机器学习的替代系统范例。在联邦学习系统中,服务器向客户端发送全局模型参数,客户端使用自身拥有的数据进行模型训练,参数上传时保留部分网络层作为本地个性化层,然后将其他模型参数发送回服务器,在服务器上这些模型参数被聚合,生成一个新的全局模型。联邦框架采用联邦平均算法作为参数聚合方法,其表达式如式(8)所示。

$$G^{j+1} = \frac{1}{T} \sum_{t=1}^T L_t^j \quad (8)$$

式中: $G^{j+1}$ 为第 $j+1$ 轮全局模型参数; $L_t^j$ 为第 $j$ 轮联邦中第 $t$ 个用户本地模型参数。

系统进行重复迭代,直到全局模型在给定任务上的性能收敛。面对“数据孤岛”问题,联邦学习能帮助多个用户搭建共享的高性能模型,并且因为这些数据不会与

其他用户共享,所以客户数据的隐私性受到保护,联邦学习框架如图3所示。




图3 联邦学习框架

Fig. 3 Federated learning framework

#### 3.2 多源信息融合

多源信息融合又被叫作多传感器信息融合,利用多个传感器采集信息,多源信息融合方法能够采集到比单一传感器更为全面和精准的信息<sup>[30]</sup>。随着各种传感器技术的快速发展,可以获得多个传感器数据。利用多源数据信息进行建模,不同的传感器数据可以提供互补的信息,提高模型的表示能力。与联邦学习相结合,可以从不同传感器学习信息,并且能够保护数据的隐私性,为了更好地学习不同传感器数据的信息,使用多模态变分自编码器(multimodal variational autoencoder, MMVAE)方法<sup>[31]</sup>。该方法能够同时处理来自多个传感器的数据,通过共享的潜在空间捕捉不同传感器数据之间的相互关系。利用这种方式,能有效地融合不同传感器的信息,从而提高模型对多源数据的分析能力,该模型结构如图4所示。




图4 多模态变分自编码器

Fig. 4 Multimodal variational autoencoder

多模态变分自编码器利用改进的ResNet神经网络作为编码器提取特征,可以有效地提高模型特征提取能力,将不同传感器的特征映射到隐变量空间,这种联合建



模方式确保模型可以从不同信号中提取互补信息,利用从编码器输出获得的均值和标准差来描述潜在空间中隐变量的分布,引入自注意力机制层(self attention, SA)自适应加权生成的隐变量,能够更好地捕捉到特征之间的相关性,通过解码器重构数据,解码器的结构与编码器相反,用反卷积、上采样替代编码器中的卷积和下采样操作,自注意力机制计算公式如式(9)所示。

$$f_{sa}(\mathbf{Q}, \mathbf{Z}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q} \cdot \mathbf{Z}^T}{\sqrt{d}}\right) \mathbf{V} \quad (9)$$

式中: $\mathbf{Q}$ 为查询矩阵; $\mathbf{Z}$ 为键矩阵; $\mathbf{V}$ 为键向量; $d$ 为键的维度;Softmax为激活函数。

MMVAE潜在空间的隐变量蕴含了原始输入数据的特征信息,本文通过改进MMVAE的模型结构,并充分挖掘隐变量中的特征信息,实现谐波减速器故障诊断,如图5所示。




图5 改进的多模态变分自编码器

Fig. 5 Improved multimodal variational autoencoder

根据本文优化的模型结构,对损失函数进行改进。首先,通过结合均方误差损失函数(mean squared error, MSE)和KL散度(Kullback-Leibler divergence, KL)的损失函数,表达式如式(10)和(11)所示。

$$L_{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2 \quad (10)$$

$$L_{KL} = \frac{1}{2} \sum_{i=1}^d (1 + \log(\sigma_i^2) - \mu_i^2 - \sigma_i^2) \quad (11)$$

式中: $x_i$ 表示原始数据; $\hat{x}_i$ 表示重构数据; $\mu_i$ 表示隐变量的均值; $\sigma_i$ 表示隐变量的方差。MSE用于评估重构数据与原始数据之间的差异,KL散度用于衡量隐变量与标准正态分布之间的相似程度,从而更好地引导模型的训练过程,得到MMVAE的损失函数,如式(12)所示。

$$L_{MMVAE} = L_{MSE} + L_{KL} \quad (12)$$

最终,将多模态变分自编码器的损失与模型分类损失如式(4)所示这两部分损失进行加权求和,作为模型的总体损失函数,如式(13)所示。

$$L = L_{class} + \omega L_{MMVAE} \quad (13)$$

式中: $\omega$ 为超参数;损失函数 $L_{class}$ 和 $L_{MMVAE}$ 的权重分别设置为1和0.01,同时对多模态变分自编码器和故障分类分支进行联合训练。通过这种方式,重构数据的生成过

程能够反向影响隐变量的生成,使隐变量更好地表征原始数据的特征信息,从而提升故障诊断的准确性。

## 4 多源不平衡数据下谐波减速器故障诊断方法

多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法流程框图如图6所示。

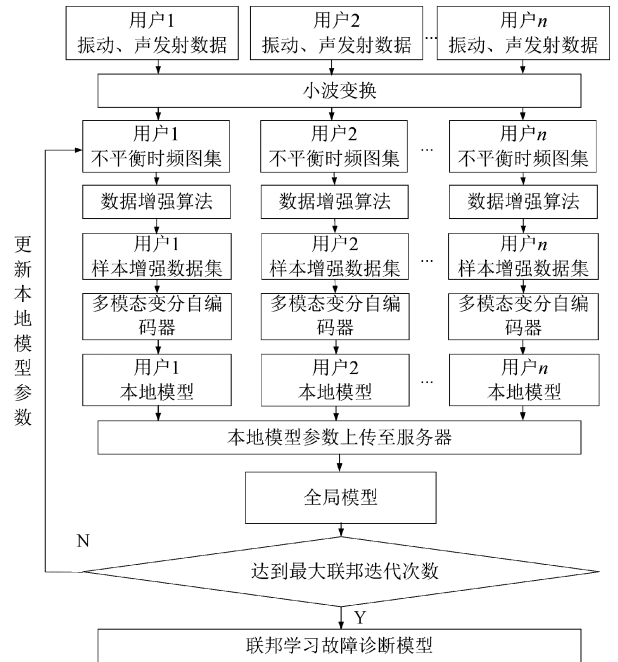


图6 故障诊断流程

Fig. 6 Flow diagram of fault diagnosis

具体步骤为:

1) 信号采集:搭建信号采集实验平台,通过安装不同故障类别的谐波减速器,进行振动信号和声发射信号的数据采集,通过上位机软件对驱动电机和负载电机进行调控,设置不同转速和载荷,实现不同工况下谐波减速器的信号采集。

2) 数据预处理:对采集到的一维信号使用小波变换,得到能够更全面直观地呈现样本时频信息的二维图像,用来构建不平衡数据集。

3) 模型构建:通过数据增强方法对不平衡数据进行数据增强。引入有效的通道注意力机制并通过可学习权重对残差分支的输出进行加权来改进网络,用改进的残差网络提取振动信号和声发射信号的特征,并通过多模态变分自编码器挖掘多源信号的互补信息,利用获得的分类损失和多模态变分自编码器的损失作为模型训练损失。在模型训练进程中,借助迭代训练的方式获取每次训练对应的损失函数值。随后,运用反向传播算法,以损

失函数为基准,对网络权重展开梯度计算,并更新参数,确保模型不断优化。在联邦学习的框架下,训练各用户端模型,并将各用户训练完成得到的本地模型参数上传到服务器,将 MMVAE 编码器部分参数上传,其他部分作为用户端的个性化层,利用联邦平均算法对参数进行参数聚合,获得全局模型,通过迭代训练,建立多源不平衡数据下谐波减速器的故障诊断模型。

4) 故障诊断:将测试集输入到训练好的故障诊断模型,得到谐波减速器故障诊断结果。

5 应用与分析

5.1 搭建信号采集实验平台

通过搭建谐波减速器信号采集平台获得本文所使用的实验数据,实验平台如图 7 所示。




图 7 信号采集平台实物图

Fig. 7 Photograph of the signal acquisition platform

测控系统如图 8 所示,利用电机控制器控制负载电机和驱动电机,设置谐波减速器的转速和负载,用加速度传感器和声发射传感器获取谐波减速器不同工况的信号,传感器布置在谐波减速器输入端 12 点钟方向。

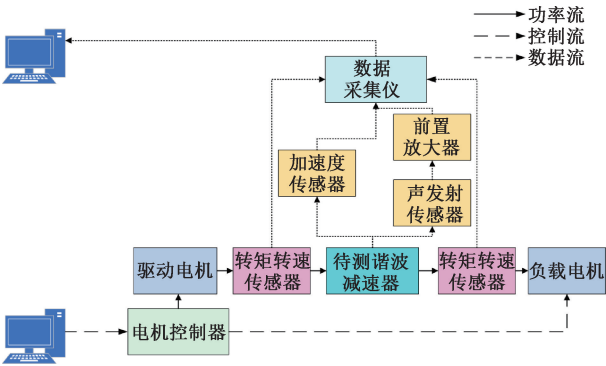


图 8 测控系统

Fig. 8 Measurement and control system

5.2 实验数据集介绍

实验的研究对象是绿的谐波 LCSG-32-50-C-I 型谐波减速器,采用人工制造故障的方式,得到 10 种状态的谐波减速器。其中,柔性轴承的轻度故障是激光烧蚀 1 次,中度故障是激光烧蚀 5 次,重度故障是激光烧蚀 10 次。

为了方便地表达谐波减速器 10 种类别数据,表达方式如表 1 所示。

表 1 不同类别数据的表达方式

Table 1 Representation methods of data in different categories

故障位置	故障程度	表示方法
正常状态	无	N
柔性轴承滚动体	重度	B10
刚轮	缺齿故障	CMT
	轻度	IR1
柔性轴承内圈	中度	IR5
	重度	IR10
	轻度	OR1
柔性轴承外圈	中度	OR5
	重度	OR10
柔轮	缺齿故障	FMT

为了模拟实际场景下,正常状态样本数量多,故障样本数量少,构建正常样本与故障样本数量比例为 2:1、10:1、20:1 和 50:1 的数据集,详细的数据集划分如表 2 所示。

表 2 不平衡数据集划分

Table 2 Imbalanced dataset partitioning

代码	样本数目				
	训练集 1 (2:1)	训练集 2 (10:1)	训练集 3 (20:1)	训练集 4 (50:1)	测试集 (1:1)
N	100	100	200	400	100
B10	50	10	10	8	100
CMT	50	10	10	8	100
IR1	50	10	10	8	100
IR5	50	10	10	8	100
IR10	50	10	10	8	100
OR1	50	10	10	8	100
OR5	50	10	10	8	100
OR10	50	10	10	8	100
FMT	50	10	10	8	100

实验中所使用的谐波减速器数据集包括 8 种工况,对不同工况数据的具体表述如表 3 所示。

对采集到的信号进行数据预处理,利用小波变换将采集到的一维信号转换为时频图。以工况 A 中柔性轴承内圈中度故障为例,图 9(a) 和(b) 分别为振动信号和声发射信号的时频图。

表 3 不同工况数据的描述

Table 3 Description of data under different working conditions

工况	负载/(N·m)	转速/(r·min <sup>-1</sup> )
A	0	1 000
B	0	1 200
C	0	1 400
D	0	1 600
E	5	1 000
F	5	1 200
G	5	1 400
H	5	1 600

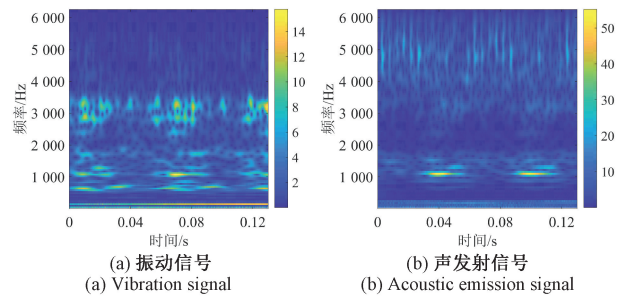


图 9 工况 A 不同信号柔性轴承内圈中度故障时频图  
Fig. 9 Time-frequency diagrams of moderate faults in the inner ring of flexible bearings for different signals under operating condition A

实验包括 8 个故障诊断任务,在每个任务中联邦学习不同用户所对应的工况如表 4 所示。

表 4 不同任务下用户端数据集设置

Table 4 Client side dataset settings under different tasks

任务编号	用户 1	用户 2	用户 3	用户 4	用户 5
1	A	B	E	F	G
2	E	G	A	C	D
3	G	H	A	B	C
4	B	D	E	F	H
5	F	H	B	C	D
6	C	D	F	G	H
7	H	A	C	F	E
8	D	E	G	B	A

本文方法中全局训练迭代次数设置为 100,学习率设置为 0.01,激活函数选择修正线性单元( rectified linear unit, ReLU)。

5.3 数据增强方法对比实验

为了验证所提数据增强方法在不平衡数据下故障诊断中的可靠性,与方法 1 和 2 进行对比,方法 1 不使用数据增强方法,采用交叉熵损失函数作为损失函数,方法 2 使用改进 Mixup 方法,采用交叉熵损失函数作为损失函数。以任务 1~4 例,在联邦学习框架下,将振动信号和声发射信号训练集 2 输入模型,利用原始残差网络对输入数据进行特征提取,具体实验结果如图 10 所示。





图 10 数据增强方法改进前后诊断结果对比  
Fig. 10 Comparing of diagnostic results before and after the improvement of the data augmentation method

根据图 10 可知,在进行不平衡数据下谐波减速器故障诊断的对比实验中,数据增强方法的改进以及损失函数的选取有利于提升模型故障诊断的能力。所提方法相对于前 2 种方法平均准确率分别提升约 7.6% 和 4.1%。


在处理不平衡数据集时,仅以分类准确率作为单一评估指标,往往难以全面、精准地反映模型性能。因此,本实验引入 G-mean 与 F-Measure 作为补充评估指标,这两者对少数类样本的分类表现更为敏感,从而更准确地衡量网络性能。将所提方法与另外 3 种方法进行对比实验。方法 1 不进行数据增强,并利用交叉熵损失函数计算训练损失;方法 2 采用改进 Mixup 方法,并利用交叉熵损失函数计算训练损失;方法 3 利用引入中心偏移权重来改进的合成少数类过采样算法<sup>[32]</sup>。以任务 1 为例,在联邦学习框架下,将振动信号和声发射信号 4 种不平衡比例的训练集输入模型,利用原始残差网络对输入数据进行特征提取,具体实验结果如图 11 所示。

根据图 11 可知,在使用 4 种不平衡比例训练集的对比实验中,所提方法相对于其他 3 种方法在 3 种评价指标上均有提高,相对于方法 1、2、3 平均准确率分别提高 9.5%、3.8% 和 4.7%。综上所述,改进 Mixup 数据增强方法和焦点损失函数的结合,可以提高模型在不平衡数据下的分类性能。






(a) 准确率对比  
(a) Comparison of accuracy rates



(b) G-mean对比  
(b) Comparison of G-mean values



(c) F-measure对比  
(c) Comparison of F-measure values

图 11 不同训练集诊断结果对比

Fig. 11 Comparison of diagnostic results of different training sets

5.4 残差网络改进前后对比实验

为了探究引入 ECA 注意力机制以及通过可学习权重加权残差分支的输出以改进网络的有效性,分别使用改进前后的残差网络提取数据特征,并通过 t-SNE 算法对特征进行可视化<sup>[33]</sup>。以任务 5 为例,在联邦学习框架

下,将振动信号和声发射信号训练集 2 输入模型,特征可视化图如图 12、13 所示。




图 12 原始残差网络特征可视化

Fig. 12 Feature visualization of the original residual network




图 13 改进残差网络特征可视化

Fig. 13 Feature visualization of the improved residual network

根据图 12 和 13 能够发现,在原始残差网络的特征可视化图中,U2 标记处类内距离较大,U1、U4、U5 和 U6 标记处有错分现象,U3 标记处类间距离较小,这两类都属于柔性轴承外圈的故障,深层特征具有一定的相似性。而残差网络改进后的特征可视化图中,虽然 U7 和 U8 标记处也存在错分的数据,然而提取的数据深层特征类别边界更加清晰,聚类较为紧密。因此,能够初步认定引入 ECA 注意力机制以及通过可学习权重加权残差分支输出以改进网络的方法可以更有效地获取谐波减速器的特征信息,能够增强模型在故障识别任务中的能力。

为了进一步验证改进残差网络在不平衡数据下谐波减速器的故障诊断中,能够有效提取数据的深层特征,采用混淆矩阵作为评估工具,清晰直观地呈现模型对各类故障状态的分类结果,如图 14 和 15 所示。




图 14 原始残差网络混淆矩阵

Fig. 14 Confusion matrix of the original residual network




图 15 改进残差网络混淆矩阵

Fig. 15 Confusion matrix of the improved residual network

由图 14 和 15 可知,通过改进前残差网络提取数据特征进行故障诊断时,对于 B10、CMT 和 OR1 这 3 类具有数量较多的错分数据,并且对于其余类数据同样具有少数错分的情况。虽然改进的残差网络仍具有错分情况,但错分数据的数目有所降低,同时 OR1 和 CMT 这两类数据的分类准确率拥有很大的提升。因此,改进的残差网络能够增强对数据关键特征的提取能力,进而更好地实现不平衡数据下谐波减速器的故障诊断。

### 5.5 多源信号与单源信号对比实验

为了验证多源信号在不平衡数据下谐波减速器故障诊断中的优越性,以任务 5~8 为例,把多源信号与各单源信号的训练集 2 输入模型,多源信号为振动信号和声发射信号,单源信号为振动信号或声发射信号。在联邦学习框架下,利用数据增强方法结合改进残差

网络完成对比实验,结果如图 16 所示。在任务 5、6 和 7 中声发射信号在单源信号中故障诊断的效果最好,在任务 8 中振动信号在单源信号中的准确率最高,但都比多源信号的故障诊断准确率低。用多源信号进行故障诊断比单源信号故障诊断的平均准确率分别提高约 1.8% 和 1.1%。




图 16 多源信号与单源信号故障诊断结果对比

Fig. 16 Comparison of fault diagnosis results between multi-source signals and single-source signals

综上所述,多源信号能够综合使用不同信号的信息进行不平衡数据下谐波减速器的故障诊断,能够避免单源信号往往不能全面刻画谐波减速器运行特性的问题。

### 5.6 多源信息融合方法改进前后对比实验

为了验证所提多源信息融合方法在谐波减速器多源不平衡数据故障诊断中的优越性,在联邦框架下,将振动信号和声发射信号训练集 2 输入到改进前后的特征提取网络,以及使用不同的方法进行特征融合,在 8 个故障诊断任务中完成实验,并通过雷达图对实验结果进行呈现,如图 17 所示。

由图 17 可知,利用改进的 MMVAE 方法进行特征融合相对于直接特征拼接方法在残差网络改进前后的 8 个故障诊断任务中准确率都实现提升。其中,利用原始残差网络提取特征进行对比时准确率平均提高 6%,利用改进的残差网络提取特征进行对比时准确率平均提高 4.3%。利用改进残差网络和 MMVAE 实现故障识别相较于原始残差网络直接进行特征拼接融合的方法在 8 个故障诊断任务中平均准确率取得了 8.7% 的提高,特别是在任务 7 中,提高 12.3%。

综上所述,改进的残差网络虽然能够提高模型的特征提取能力以及动态地调整对不同特征的关注意度,但是对于多源信号,直接采用特征拼接的方法不能充分挖掘不同信号之间的潜在关联。MMVAE 使得模型能够在隐变量空间中挖掘不同信号之间的互补信息,并通过自注意力机制对不同信号的特征进一步处理,

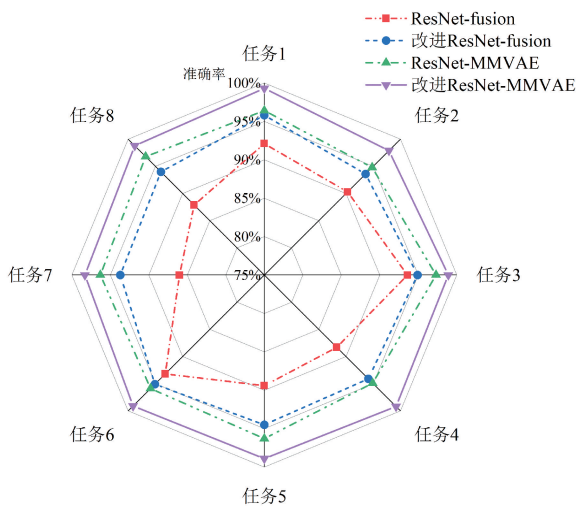


图 17 多源信息融合方法改进前后对比结果  
Fig. 17 Comparison of results before and after the improvement of the multi-source information fusion method

增强特征表示,从而增强模型对多源信号的处理能力,进而提升模型在多源不平衡数据下对谐波减速器故障诊断的能力。

5.7 所提方法与其他多源信息融合方法对比

为了进一步验证所提方法在多源不平衡数据下对谐波减速器故障诊断的优越性,将所提方法与混合多尺度卷积神经网络 (hybrid multi-scale convolutional neural network, HMS-MACNN)、组归一化并行卷积神经网络 (group normalization parallel convolutional neural networks, GPCNN)、自注意力-动态自适应卷积神经网络 (self attention-dynamic adaptive convolutional neural network, SA-DACNN)、深度残差神经网络 (deep residual neural network, DRNN) 4 种多源信息融合方法进行对比实验。将振动信号和声发射信号训练集 2 输入模型,在 8 个故障诊断任务中完成实验,实验结果如图 18 所示。

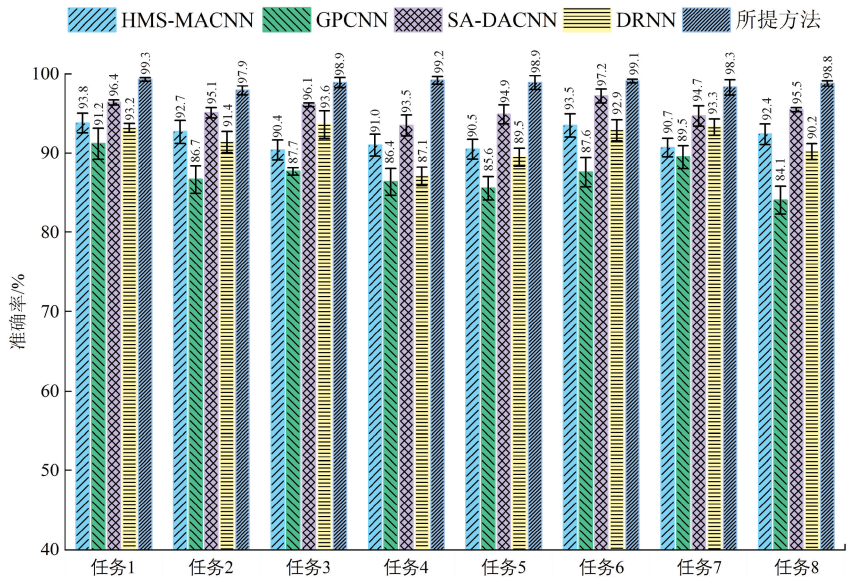


图 18 所提方法与其他多源信息融合方法的对比结果  
Fig. 18 Comparison results of the proposed method with other multi-source information fusion methods

由图 18 可知,在 8 个故障诊断任务中,所提方法相对于其他多源信息融合方法的诊断准确率都有提升,平均准确率为 98.8%,且相比于 HMS-MACNN、GPCNN、SA-DACNN、DRNN 的多源信息融合方法,平均准确率分别有 6.9%、11.4%、3.4%和 7.4%的提升,由上述实验可知,所提方法在多源不平衡数据下谐波减速器故障诊断的优越性。

6 结 论

针对工业机器人谐波减速器正常状态样本多于故障类别样本以及单源信号不易充分刻画谐波减速器运行特

征,不同用户之间隐私数据不共享,导致诊断准确率不高的问题,提出一种多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法。通过搭建谐波减速器信号采集平台进行验证,得出结论为:

1) 提出改进 Mixup 并结合焦点损失函数解决数据不平衡的方法,根据不同类别的样本数量,动态调整数据的采样策略,结合焦点损失函数,使模型更关注训练中错分类较多的类别,所提方法相对于其他方法平均准确率分别提升 9.5%、3.8%和 4.7%。通过 3 种指标评价方法的有效性,验证了所提方法使模型在数据不平衡下分类能力有所提升。



2) 提出在残差网络中引入有效的通道注意力机制并用可学习权重加权残差分支输出的特征提取网络方法,调整模型对不同特征的关注程度,更好地挖掘数据深层特征。通过特征可视化和混淆矩阵方法,验证了改进的残差网络能够提升对谐波减速器故障特征的提取能力。

3) 提出一种多源不平衡数据下基于联邦学习的谐波减速器故障诊断方法。该方法在个性化联邦学习框架下,保障不同用户数据隐私,通过改进多模态变分自编码器挖掘不同信号之间的互补信息,利用自注意力机制对特征信息自适应调整,在多源不平衡数据下,建立有效的谐波减速器故障诊断模型。通过8个故障诊断任务进行验证,所提方法平均准确率为98.8%,相较其余对比方法,故障诊断准确率至少提升3.4%。

实验中已通过谐波减速器实测数据对故障诊断方法进行了充分的实验验证,下一步将针对谐波减速器复合故障数据,以及其他旋转机械部件数据进行实验研究。

## 参考文献

- [1] 张弦,王鹏,张昌明,等. 谐波减速器精度退化失效及相关竞争失效可靠度评估研究[J]. 振动与冲击, 2024, 43(15): 277-287.  
ZHANG X, WANG P, ZHANG CH M, et al. Research on the reliability evaluation of precision degradation failure and related competing failures of harmonic reducer[J]. Journal of Vibration and Shock, 2024, 43(15): 277-287.
- [2] 潘柏松,薛舒晨,谢少军,等. 基于柔轮裂纹扩展的谐波减速器剩余寿命预测方法[J]. 计算机集成制造系统, 2024, 30(11): 4030-4041.  
PAN B S, XUE SH CH, XIE SH J, et al. Remaining useful life prediction method of harmonic reducer based on the crack propagation of the flex-spline[J]. Computer Integrated Manufacturing Systems, 2024, 30(11): 4030-4041.
- [3] JIA Y ZH, LI Y Q, XU M Q, et al. A fault diagnosis scheme for harmonic reducer under practical operating conditions[J]. Measurement, 2024, 227: 114234.
- [4] 康守强,肖杨,王玉静,等. 基于联邦模型迁移的不同规格滚动轴承故障诊断方法[J]. 振动与冲击, 2023, 42(22): 184-192.  
KANG SH Q, XIAO Y, WANG Y J, et al. Fault diagnosis method for different specification rolling bearings based on the method of federated model transfer learning[J]. Journal of Vibration and Shock, 2023, 42(22): 184-192.
- [5] ZHOU X, ZHOU H CH, HE Y M, et al. Harmonic reducer in-situ fault diagnosis for industrial robots based on deep learning [J]. Science China Technological Sciences, 2022, 65(9): 2116-2126.
- [6] HE Y M, CHEN J H, ZHOU X, et al. In-situ fault diagnosis for the harmonic reducer of industrial robots via multi-scale mixed convolutional neural networks [J]. Journal of Manufacturing Systems, 2023, 66: 233-247.
- [7] 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.
- [8] 郭莹莹,赵学智,上官文斌,等. 柔性椭圆轴承故障频率分析与CMWT-FH特征提取[J]. 机械工程学报, 2019, 55(23): 154-161.  
GUO Y Y, ZHAO X ZH, SHANGGUAN W B, et al. Fault frequency analysis of flexible elliptical bearings and feature extraction using CMWT-FH [J]. Journal of Mechanical Engineering, 2019, 55(23): 154-161.
- [9] LI K, YANG R G, WEI T C, et al. Fault diagnosis of the harmonic reducer based on dual-path convolutional network with multi-channel hybrid attention mechanism[J]. Measurement Science and Technology, 2024, 36(1): 016130.
- [10] 孟宗,关阳,潘作舟,等. 基于二次数据增强和深度卷积的滚动轴承故障诊断研究[J]. 机械工程学报, 2021, 57(23): 106-115.  
MENG Z, GUAN Y, PAN Z ZH, et al. Research on fault diagnosis of rolling bearings based on secondary data augmentation and deep convolution [J]. Journal of Mechanical Engineering, 2021, 57(23): 106-115.
- [11] HANG Q, YANG J H, XING L N. Diagnosis of rolling bearing based on classification for high dimensional unbalanced data [J]. IEEE Access, 2019, 7: 79159-79172.
- [12] SU Y H, MENG L, KONG X J, et al. Generative adversarial networks for gearbox of wind turbine with unbalanced data sets in fault diagnosis[J]. IEEE Sensors Journal, 2022, 22(13): 13285-13298.
- [13] LU F Y, TONG Q B, FENG Z W, et al. Unbalanced bearing fault diagnosis under various speeds based on spectrum alignment and deep transfer convolution neural

- network[J]. IEEE Transactions on Industrial Informatics, 2022, 19(7): 8295-8306.
- [14] LU J T, WU W, HUANG X, et al. A modified active learning intelligent fault diagnosis method for rolling bearings with unbalanced samples[J]. Advanced Engineering Informatics, 2024, 60: 102397.
- [15] 张洪亮, 余其源, 秦超群, 等. 基于信息融合及双连接注意力残差网络的轴承故障诊断[J]. 振动与冲击, 2023, 42(20): 114-123.
- ZHANG H L, YU Q Y, QIN CH Q, et al. Bearing fault diagnosis based on double-connected attention residual network and information fusion[J]. Journal of Vibration and Shock, 2023, 42(20): 114-123.
- [16] WU J, JIANG L L, LI J F, et al. Discovering new prognostic features for the harmonic reducer in remaining useful life prediction[J]. Shock and Vibration, 2023, 2023(1): 2381638.
- [17] SHAO H D, LIN J, ZHANG L W, et al. A novel approach of multisensory fusion to collaborative fault diagnosis in maintenance[J]. Information Fusion, 2021, 74: 65-76.
- [18] ZHAO X L, JIA M P, DING P, et al. Intelligent fault diagnosis of multichannel motor-rotor system based on multimanifold deep extreme learning machine[J]. IEEE/ASME Transactions on Mechatronics, 2020, 25(5): 2177-2187.
- [19] HSIEH N K, YU T Y. Fault detection in harmonic drive using multi-sensor data fusion and gravitational search algorithm[J]. Machines, 2024, 12(12): 831.
- [20] LIU Q, WANG H P. A case study on multisensor data fusion for imbalance diagnosis of rotating machinery[J]. Artificial Intelligence for Engineering Design, Analysis and Manufacturing, 2001, 15(3): 203-210.
- [21] 康守强, 章炜东, 王玉静, 等. 基于信息融合子域适应的不同工况下谐波减速器故障诊断方法[J]. 仪器仪表学报, 2024, 45(3): 60-71.
- KANG SH Q, ZHANG W D, WANG Y J, et al. Fault diagnosis method of harmonic reducer under different working conditions based on information fusion subdomain adaptation[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 60-71.
- [22] ZHANG Y CH, YU K, LEI Z H, et al. Integrated intelligent fault diagnosis approach of offshore wind turbine bearing based on information stream fusion and semi-supervised learning[J]. Expert Systems with Applications, 2023, 232: 120854.
- [23] 康守强, 杨加伟, 王玉静, 等. 基于联邦多表示域适应的不同工况下滚动轴承故障诊断方法[J]. 仪器仪表学报, 2023, 44(6): 165-176.
- KANG SH Q, YANG J W, WANG Y J, et al. Fault diagnosis method of rolling bearings under different working conditions based on federated multi-representation domain adaptation[J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 165-176.
- [24] LI ZH N, LI Z D, LI Y L, et al. An intelligent diagnosis method for machine fault based on federated learning[J]. Applied Sciences, 2021, 11(24): 12117.
- [25] ZHANG J L, DUAN L X, LI K, et al. Improved lightweight federated learning network for fault feature extraction of reciprocating machinery[J]. Measurement Science and Technology, 2024, 35(4): 045115.
- [26] MEHTA M, CHEN S Y, TANG H CH, et al. A federated learning approach to mixed fault diagnosis in rotating machinery[J]. Journal of Manufacturing Systems, 2023, 68: 687-694.
- [27] ZHANG H Y, CISSE M, DAUPHIN Y N, et al. Mixup: Beyond empirical risk minimization[C]. International Conference on Learning Representations, 2018: 1-13.
- [28] 宋文强, 徐伟, 冯琳. 基于残差网络的地基云图识别方法研究[J]. 电子测量技术, 2024, 47(2): 185-192.
- SONG W Q, XU W, FENG L. Research on ground-based cloud image recognition method based on residual network[J]. Electronic Measurement Technology, 2024, 47(2): 185-192.
- [29] 姜媛媛, 蔡梦南. 轻量化的印刷电路板缺陷检测网络 Multi-CR YOLO[J]. 电子测量与仪器学报, 2023, 37(11): 217-224.
- JIANG Y Y, CAI M N. Lightweight printed circuit board defect detection network Multi-CR YOLO[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(11): 217-224.
- [30] 肖立峰. 基于多源信息融合的旋转机械滚动轴承故障诊断方法研究[D]. 秦皇岛: 燕山大学, 2023.
- XIAO L F. Research on fault diagnosis methods of rolling bearings of rotating machinery based on multi-source information fusion[D]. Qinhuangdao: Yanshan University, 2023.
- [31] SHI Y, PAIGE B, TORR P. Variational mixture-of-experts autoencoders for multi-modal deep generative

models[J]. Advances in Neural Information Processing Systems, 2019, 32: 1-19.

[32] 朱莉,汪小豪,李豪,等. 不平衡样本下基于变异麻雀搜索算法和改进 SMOTE 的变压器故障诊断方法[J]. 高电压技术, 2023, 49(12): 4993-5001.

ZHU L, WANG X H, LI H, et al. Transformer fault diagnosis method based on variational sparrow search algorithm and improved smote under imbalanced samples[J]. High Voltage Engineering, 2023, 49(12): 4993-5001.

[33] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(2605): 2579-2605.

作者简介



王玉静,2004 年于哈尔滨理工大学获得学士学位,2007 年于哈尔滨理工大学获得硕士学位,2015 年于哈尔滨工业大学获得博士学位,现为哈尔滨理工大学教授、博士生导师,主要研究方向非平稳信号处理,故障诊断、状态评估与预测技术。

E-mail:mirrorwyj@163.com

**Wang Yujing** received her B.Sc. degree from Harbin University of Science and Technology in 2004, received her M. Sc. degree from Harbin University of Science and Technology in 2007, received her Ph.D. degree from Harbin Institute of Technology in 2015. Now she is a professor and doctoral supervisor in Harbin University of Science and Technology. Her main research interests include non-stationary signal processing, fault diagnosis, state evaluation and prediction technology.



叶柏宏,2020 年于哈尔滨理工大学获得学士学位,现为哈尔滨理工大学硕士研究生,主要研究方向为非平稳信号处理,故障诊断、状态评估与预测技术。

E-mail:2290212496@qq.com

**Ye Baihong** received his B. Sc. degree from


Harbin University of Science and Technology in 2020. Now he is pursuing his M. Sc. degree at Harbin University of Science and Technology. His main research interests include non-stationary signal processing, fault diagnosis, state evaluation and prediction technology.



康守强(通信作者),2004 年于哈尔滨理工大学获得学士学位,2007 年于哈尔滨理工大学获得硕士学位,2011 年于白俄罗斯国立大学获得博士学位,现为哈尔滨理工大学教授、博士生导师,主要研究方向为非平稳信号处理,故障诊断、状态评估与预测技术。

E-mail:kangshouqiang@163.com

**Kang Shouqiang** (Corresponding author) received his B. Sc. degree from Harbin University of Science and Technology in 2004, received his M. Sc. degree from Harbin University of Science and Technology in 2007, received his Ph. D. degree from Belarusian State University in 2011. Now he is a professor and doctoral supervisor in Harbin University of Science and Technology. His main research interests include non-stationary signal processing, fault diagnosis, state evaluation and prediction technology.



刘连胜,2006 年、2008 年和 2017 年于哈尔滨工业大学分别获得学士、硕士和博士学位,现为哈尔滨工业大学副教授、博士生导师,主要研究方向为信息物理系统、基于 FPGA 的高能效计算技术、故障预测与健康管理等。

E-mail:lianshengliu@hit.edu.cn

**Liu Liansheng** received his B.Sc., M.Sc., and Ph.D. degrees all from Harbin Institute of Technology in 2006, 2008, and 2017, respectively. He is currently an associate professor and a Ph. D. advisor at Harbin Institute of Technology. His main research interests include cyber-physical systems, FPGA-based energy-efficient computing technology, fault prognostics and health management, etc.