

DOI: 10.19650/j.cnki.cjsi.J2513726

改进 ResNet 结合 MKSVDD 的谐波减速器 多状态同尺度定量评估方法*

孙宇林¹, 罗 双¹, 康守强¹, 王玉静¹, 刘连胜²

(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:针对谐波减速器故障程度难以精确量化以及不同故障位置无法在同一尺度下定量分析的问题,提出一种改进深度残差网络(ResNet)结合多核支持向量数据描述(MKSVDD)的谐波减速器多状态同尺度下的定量评估方法。该方法首先提出一种新的谐波减速器多状态同尺度定量评估框架,并对微弱故障敏感的声发射信号进行连续小波变换构建二维时频图数据集;其次提出卷积注意力模块改进 ResNet 以充分挖掘二维时频图的深层特征;再引入多核核函数改进支持向量数据描述,基于谐波减速器正常状态的深层特征构建 MKSVDD 健康状态评估模型;然后,计算不同故障程度的特征相对于正常状态球心的距离,构建评估指标,通过拟合得到定量评估曲线;此外,根据谐波减速器的结构和声发射信号传播机理,提出相对距离补偿方案以构建多状态评估指标,实现谐波减速器不同健康状态在同一尺度下的定量评估。通过搭建谐波减速器实验台,对未知故障程度的数据进行多组对比实验的结果表明,改进后的深度残差网络提取到的特征更聚集,所提方法能实现谐波减速器不同故障位置在同一尺度下的定量分析,且评估误差不超过 3.2%,有效完成谐波减速器多状态同尺度的定量评估。

关键词:谐波减速器;卷积注意力机制;多核支持向量数据描述;多故障状态;定量评估

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

Same-scale quantitative assessment method for multiple states of a harmonic reducer based on improved ResNet and MKSVDD

Sun Yulin¹, Luo Shuang¹, Kang Shouqiang¹, Wang Yujing¹, Liu Liansheng²

(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:To address the difficulty in accurately quantifying the fault degree of harmonic reducers and the inability to perform same-scale quantitative analysis for different fault locations, a same-scale quantitative assessment method is proposed for multiple states of harmonic reducer based on improved deep residual network (ResNet) and multi-kernel support vector data description (MKSVDD). First, a new same-scale quantitative assessment framework for multiple states of harmonic reducer is proposed, and continuous wavelet transform is applied to acoustic emission signals sensitive to weak faults to construct a two-dimensional time-frequency image dataset. Then, a convolutional attention module is used to improve ResNet in order to fully extract the deep features of the two-dimensional time-frequency images. Furthermore, a multi-kernel function is introduced to enhance the support vector data description, and an MKSVDD health state assessment model is constructed based on the deep features of the harmonic reducer in the normal state. Next, the distance between the features of different fault degrees and the center of the hypersphere under the normal condition is calculated to construct the assessment indicators, and the quantitative assessment curve is obtained by fitting these indicators. In addition, based on the structure of the harmonic reducer and the propagation mechanism of acoustic emission signals, a relative distance compensation scheme is proposed to construct the multi-state assessment indicator, thereby achieving quantitative assessment of different health states for harmonic reducer

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

* 基金项目:国家自然科学基金项目(52375533)、黑龙江省自然科学基金项目(PL2024F018)、山东省自然科学基金项目(ZR2023ME057)、哈尔滨市制造业科技创新人才项目(2023CXRC017)资助

under a unified scale. Through the establishment of a harmonic reducer test bench and multiple comparative experiments on data with unknown fault degrees, the results show that the features extracted by the improved deep residual network are more compact. The proposed method enables same-scale quantitative assessment of different fault locations, with an assessment error not exceeding 3.2%, effectively completing the same-scale quantitative assessment of harmonic reducer in multiple states.

Keywords: harmonic reducer; convolutional attention mechanism; multi-kernel support vector data description; multiple fault states; quantitative assessment

0 引 言

《“机器人+”应用行动实施方案》明确提出要加快推进机器人产业化进程,工业机器人作为自动化领域的重要的核心组成部分,凭借精度高、低运行成本等优势,在军事、医疗、航空航天、人机交互等领域得到广泛应用^[1]。谐波减速器作为其关节部位的核心组件,在保障工业机器人安全、精准、稳定运行方面发挥着不可或缺的关键作用^[2]。由于工业机器人的工作特点,谐波减速器一般执行周期性往复运动,容易引发自身性能退化或失效问题,轻则导致生产线出现非计划中断,重则可能危及工人生命安全^[3-4]。谐波减速器运行周期内通常会历经正常运行、不同程度故障显现直至完全失效的完整历程,在此情境下,精确且定量地评估谐波减速器的运行状态是保障工业机器人正常运转的先决条件。因此,以故障诊断技术为基础,研究谐波减速器从完好无损到一系列故障程度的退化规律,从而实现谐波减速器的健康状态定量评估具有重要的理论价值和现实意义。

近年来,人工智能的发展态势蓬勃,以深度学习为代表的驱动方法已经在谐波减速器等旋转机械故障诊断领域得到了广泛的应用。文献[5]利用卷积神经网络从融合多个传感器信息的时频图中提取故障特征,有效实现谐波减速器的故障诊断。文献[6]提出生成对抗网络和数据选择模块解决谐波减速器数据不平衡的问题,并利用多尺度卷积神经网络实现谐波减速器健康状态多分类。文献[7]采用卷积神经网络从谐波减速器电压信号转换成的时频图中提取可表征不同健康状态的深度特征,实现对谐波减速器的有效故障诊断。文献[8]提取出一种多传感器信息融合方法,并利用子域适应和多表示特征学习网络有效实现无监督场景中不同工况下的谐波减速器故障分类。文献[9]以谐波减速器连续时域振动信号为输入数据,将一维卷积神经网络与矩阵核自适应模型相结合作为故障诊断模型,通过谐波减速器实际运行信号数据验证了所提故障诊断模型的有效性。文献[10]提出一种基于个性化联邦学习的谐波减速器故障诊断方法,利用卷积神经网络作为用户本地诊断模型,提取时频图特征,有效实现了数据孤岛下谐波减速器协同故障诊断。

深度学习方法为高效提取故障特征并完成故障诊断工作提供了可行思路,但在训练深度神经网络时,为了增强网络的特征提取能力,往往需要设置较多的卷积通道,但是各个通道中的有用故障信息占比呈现不均衡状态^[11]。因此,通过在深度学习模型中添加注意力机制模块,提高有用信息的关注度,从而提高模型对故障信息的处理与学习能力。注意力机制是一种灵活的模块,能够集成至网络架构的任意层级。它可引导网络模型着重关注图像的关键特征,同时降低其余非关键特征对预测结果的影响。文献[12]利用多注意力机制增强诊断模型对故障特征的关注度,通过自建轴承实验台数据集验证改进模型分类准确率有明显提高。文献[13]提出一种多尺度注意力机制用于增强卷积神经网络对故障特征的学习能力,有效实现齿轮箱的故障诊断。文献[14]提出建立具有两种不同关注点的并行卷积神经网络,用于提取减速器故障相关的深度特征,提高了故障诊断的准确率。文献[15]提出一种改进的深度残差网络的故障诊断方法,通过通道注意力机制获取通道全局信息并对权重进行调整,以此增强网络的泛化能力,有效实现了不同负载滚动轴承的故障诊断。文献[16]在卷积神经网络架构中引入多尺度注意力机制,引导模型关注全局和局部关键故障信息,建立多尺度特征增强模块,剔除无用特征,在变工况条件下实现了齿轮箱和轴承的故障诊断。

上述基于注意力机制和深度学习方法在旋转机械故障诊断领域取得了很好的成果,但大多侧重于故障位置的判别,对于故障程度的定量刻画尚未给予充分关注和深入探究。然而,在实际工业生产中,谐波减速器等旋转机械设备对故障程度的定量分析较于故障分类更为重要。在健康状态定量评估范畴内,评估指标主要分为两大类:概率似然值指标和距离型指标。如高斯混合模型、连续隐马尔可夫模型和贝叶斯网络等都是建立概率似然指标。概率似然值指标取值范围通常在 $[0, 1]$,但该指标存在过饱和问题;当故障尚未发展至最严重状态时,待测信号特征与无故障信号特征的相似概率就已降至0,即便故障程度持续加剧,其数值也不再发生改变,因此难以准确刻画旋转机械的失效状况^[17]。距离型指标随着旋转机械的退化过程表现出良好的单调趋势,如支持向量机和支向量数据描述(support vector data description, SVDD)等。SVDD被广泛应用于旋转机械性能退化评估

领域中,与支持向量机相比,其单值分类效果更显著、更准确。文献[18]提出一种考虑全局和局部特征提取与SVDD相结合的退化指标提取方法,采用正常状态向量训练SVDD模型,构建距离型退化指标,实现了滚动轴承的性能退化评估。文献[19]提出一种基于综合指标缩减和SVDD的滚动轴承性能退化评估方法,结合时域、频域指标构建轴承综合特征指标集,采用局部线性嵌入算法对提取主要故障特征进行降维,以待测样本到正常样本训练得到的球心的距离描述性能退化程度,来表征和评价滚动轴承的寿命退化过程,客观地揭示了滚动轴承的性能退化过程。文献[20]采用深度信念网络提取滚动轴承的故障特征,通过SVDD构建评估模型,有效实现轴承的性能退化评估。

上述采用距离型评估指标在旋转机械性能退化评估领域取得了较好的效果,但仅局限于特定故障位置条件下的性能退化分析,不仅未对故障程度进行精确量化,而且无法在同一尺度下对不同的故障位置进行故障程度的量化分析,进而限制了定量评估的精确性。

基于上述原因,针对现有研究难以对谐波减速器的故障程度量化分析以及无法在统一尺度下对不同位置的故障程度进行评估的问题,以谐波减速器为研究对象,声发射信号为信号监测源,提出一种改进ResNet(residual network, ResNet)结合多核支持向量数据描述(multi-kernel SVDD, MKSVDD)的谐波减速器多状态同尺度定量评估方法。该方法在原始残差网络中引入卷积注意力模块,搭建更能专注重要故障信息的特征提取网络,提出MKSVDD评估模型,构建能够反映谐波减速器故障退化规律的距离指标,根据传感器安装位置与故障的相对位置提出补偿距离并构建多状态评估指标,最终实现谐波减速器的多状态同尺度下的定量评估。

1 连续小波变换

连续小波变换(continuous wavelet transform, CWT)是处理时变、非平稳信号的一种时频分析方法,其原理是通过将信号与经平移和缩放的小波函数做卷积运算,从而得到信号的时频表示形式^[21]。CWT可以根据信号的特点调节窗口大小,进行多分辨率分析,捕捉信号在时间和频率上的局部特性。CWT的表达式如式(1)所示。

$$CWT(p, q) = \frac{1}{\sqrt{p}} \int_{-\infty}^{+\infty} A(t) \psi^* \left(\frac{t-q}{p} \right) dt \quad (1)$$

式中: $A(t)$ 是输入信号; $\psi(t)$ 是小波基函数; $\psi^*(t)$ 表示小波函数的共轭; p 是尺度因子; q 是平移因子。

由于复数 morlet 小波 (complex morlet, Cmor) 的波形与轴承故障引起的冲击特征相似,同时具有良好的自适应性,所以在轴承的故障诊断和状态评估领域中,通常以

Cmor 小波作为小波基函数,具体表达式如式(2)所示。

$$\psi(t) = \frac{1}{\sqrt{\pi B}} e^{-\frac{t^2}{B}} e^{i2\pi\theta t} \quad (2)$$

式中: B 为带宽因子; θ 为中心频率因子; e 为自然常数。

2 改进的残差网络

2.1 残差网络

残差网络 ResNet^[22-23] 是基于残差块的改进卷积神经网络,残差块是组成残差网络的重要单元,其具体结构如图1所示。残差块的运行方式是在网络层中完成恒等映射操作后,将该操作的结果与非线性变换所得的结果进行叠加,将叠加后的值作为输出。通过仅学习残差块输入与输出之间差值,有效解决了卷积神经网络随着层数增多而出现的梯度消失等难题,降低了模型训练的难度。残差块的输入为 x_{in} , 输出为 $H(x)$, 残差即为 $H(x)$ 与 x_{in} 的差值,如式(3)所示。

$$f(x) = H(x) - x_{in} \quad (3)$$




图1 残差块结构

Fig. 1 The architecture of residual block

2.2 改进后的残差网络

虽然原始残差网络已经具备特征提取能力,但是对于不同通道信息而言,没有取舍和侧重,因此会造成计算资源的浪费和识别能力的下降。注意力机制能自适应地学习和计算出输入数据对输出数据影响的权重大小,从而使神经网络模型更关注必要的特征并抑制不重要的特征,从而提高计算机图像分类任务中的识别准确率。

卷积注意力模块(convolutional block attention module, CBAM)^[24-25] 包含两部分,分别是:通道注意力模块与空间注意力模块,CBAM的结构如图2所示。该模块的工作流程为:先对特征图的通道注意力进行计算,得到经通道注意力加权后的特征图;再以这一特征图为基础,进一步开展空间注意力的计算,从而获得空间注意力加权的特征图,由此形成“级联”效应。

通道注意力机制如式(4)所示。

$$M_c(X) = \phi(W_1(W_0(X_{avg}^c)) + W_1(W_0(X_{max}^c))) \quad (4)$$

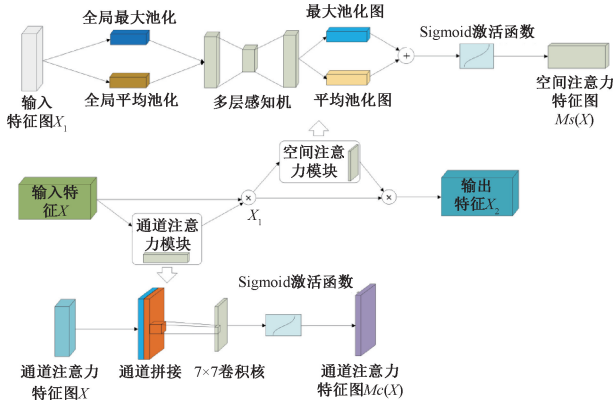


图 2 CBAM 注意力模块结构

Fig. 2 Architecture diagram of CBAM attention module

式中: M_c 表示通道注意力模块的一维卷积运算; ϕ 为 sigmoid 激活函数; W_0 、 W_1 代表多层感知机的两个隐藏层; X_{avg}^c 是通道维度下进行平均池化操作后得到的特征; X_{max}^c 为通道维度下进行最大池化操作后得到的特征。

空间注意力机制如式(5)所示。

$$M_s(X) = \phi(f^{7 \times 7}([X_{avg}^s, X_{max}^s])) \quad (5)$$

式中: M_s 表示空间注意力模块的二维卷积运算; $f^{7 \times 7}$ 为卷积核尺寸为 7×7 的图像卷积运算; X_{avg}^s 表示空间维度下的进行平均池化操作后得到的特征; X_{max}^s 表示空间维度下进行最大池化操作后得到的特征。

CBAM 由通道注意力机制和空间注意力机制级联组成,如式(6)和(7)所示。

$$X_1 = M_c(X) \otimes X \quad (6)$$

$$X_2 = M_s(X_1) \otimes X_1 \quad (7)$$

式中: X 为输入特征图; X_1 是经过式(4)后的特征图; X_2 代表经过式(5)后的特征图; \otimes 表示逐个像素相乘。

改进后的残差网络结构如图 3 所示,将 CBAM 模块嵌入到残差网络的尾端。




图 3 基于 CBAM 的残差网络

Fig. 3 The residual network based on CBAM

过 CBAM 模块,让网络自适应的获取和谐波减速器故障状态相关的通道信息和空间信息,得到更为精细化的特征表示。基于通道注意力和空间注意力机制的残差网络的输出如式(8)所示。

$$\Theta(f(x)) + x_{in} \quad (8)$$

式中: x_{in} 为输入; $f(x)$ 是残差函数; Θ 为 CBAM 注意力函数。

3 多核支持向量数据描述

3.1 支持向量数据描述

SVDD^[26] 能够将正常状态的样本聚集为一个类别,将其他样本归为另一类别,但其机制与典型的二分类模型又有所不同。其核心思想是在训练过程中构建一个最小超球体,该超球体尽可能多地包含训练样本,同时把非目标样本排除在超球体之外。二维 SVDD 如图 4 所示。




图 4 SVDD 二维二维示意图

Fig. 4 Schematic diagram of two-dimensional SVDD

针对目标样本集 $M = \{x_1, x_2, \dots, x_N\}$, 构建一个能够涵盖全部或者大多数目标类样本的最优超球体,该超球由两个变量描述,分别是:中心 O 和半径 R ,构建好的超球应满足以下优化函数如式(9)所示。

$$\begin{cases} \min L(R, O, \xi_i) = R^2 + C \sum_{i=1}^n \xi_i \\ \text{s. t. } \|x_i - O\|^2 \leq R^2 + \xi_i \end{cases} \quad (9)$$

式中: C 为惩罚参数,控制超球体误差和算法复杂度之间的平衡; ξ_i 为松弛变量,允许一些训练数据在超球体之外。

引入拉格朗日乘子 α_i , 转化为拉格朗日求极值问题,如式(10)所示。

$$\begin{cases} \max L = \sum_{i=1}^n \alpha_i x_i x_j - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j x_i x_j \\ \text{s. t. } \sum_{i=1}^n \alpha_i = 1, \quad 0 \leq \alpha_i \leq C \end{cases} \quad (10)$$

由于输入空间内的数据不具备线性可分性,因此可借助核函数将样本从低维空间的线性不可分状态映射至高维空间,使其实现线性可分。在高维空间中,样本能够得到更精准的描述。在映射空间中, R 通过计算任意一个支持向量到中心点的距离来确定,如式(11)所示。

通过卷积操作能提取信息特征,将提取到的特征通

$$R^2 = K(x_k, x_k) - 2 \sum_{i=1}^n \alpha_i K(x_i, x_k) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(x_i, x_j) \quad (11)$$

式中: $K(\cdot)$ 为核函数, 代表内积运算。

对于新样本 y , 其与球心的距离如式 (12) 所示。

$$D = K(y, y) - 2 \sum_{i=1}^n \alpha_i K(y, x_i) + \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j K(x_i, x_j) \quad (12)$$

3.2 多核函数的构造

在算法设计时, 为将低维空间中原本线性不可分的问题转化为高维空间中的线性可分问题, 核函数是重要方法之一。在 SVDD 分类中, 常使用单一核函数。但谐波减速器运行环境多变导致故障数据高度复杂, 导致单一核函数构造的 SVDD 模型难以取得很好的效果。

根据核函数的性质, 将多个核函数以线性加权的方式进行组合, 构造的多核核函数 K_m 依然满足 Mercer 定理, 多核核函数的构造方法如式 (13) 所示。

$$K_{mix}(x_i, x_j) = \sum_{m=1}^M \mu_m K_m(x_i, x_j) \quad (13)$$

式中: K_{mix} 表示多个核函数的叠加; M 代表核函数的数量; 满足权值 $\mu_m \geq 0$, $\sum_{m=1}^M \mu_m = 1$ 。

由于高斯径向基核函数比其它常见的核函数具有更强的描述样本分布的能力, 使其对相对较窄的区间内的输入向量可产生较大影响, 可以更有效地处理谐波减速器故障数据高度复杂的情况。高斯径向基核函数的定义如式 (14) 所示。

$$K(x_i - x_j) = e^{-\frac{\|x_i - x_j\|^2}{\sigma^2}} \quad (14)$$

式中: σ 为核函数宽度参数。

为构造有效的多核核函数, 可通过对 2 个具有不同核宽度的高斯径向基核函数采用线性加权策略进行构造, 从而提高多核核函数的学习能力和泛化能力, 具体形式如式 (15) 所示。

$$K_{mix} = \mu K_{rbf, \sigma_1} + (1 - \mu) K_{rbf, \sigma_2} \quad (15)$$

式中: K_{rbf} 是高斯径向基核函数; σ_1 和 σ_2 是 2 种不同核函数的宽度参数。为了对 2 个核函数的权值进行控制, 权值系数 μ 的取值为 $\mu \in [0, 1]$ 。

4 谐波减速器健康状态定量评估方法及流程

基于改进残差网络结合多核支持向量数据描述的谐波减速器多状态同尺度定量评估方法框图如图 5 所示。

具体步骤为:

1) 数据采集: 将待测谐波减速器装配到固定装置上,

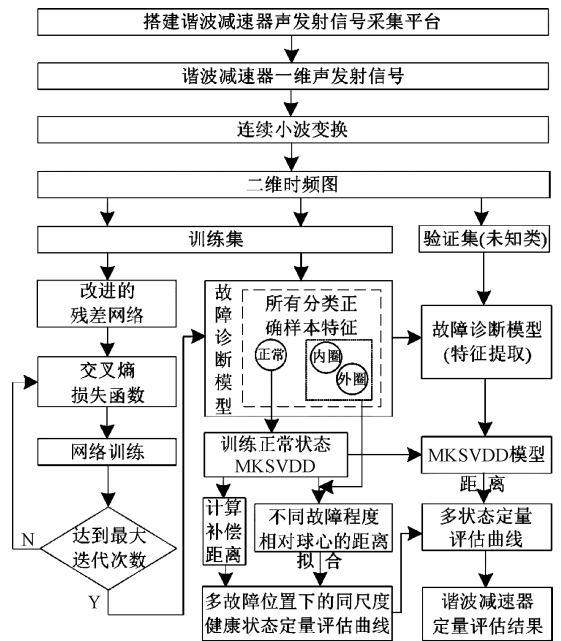


图 5 谐波减速器多状态同尺度定量评估流程

Fig. 5 Flow chart of same-scale quantitative assessment in multiple states of harmonic reducer

完成谐波减速器声发射信号采集实验平台的搭建。通过编辑和执行电机控制程序, 对负载电机中的扭矩和驱动电机中的转速等相关参数进行设定, 完成不同工况下谐波减速器多种故障位置和故障程度的声发射信号采集。

2) 数据预处理: 利用小波变换将一维信号转换成二维时频图, 制作不同故障位置及不同故障程度谐波减速器声发射信号的时频图数据集。

3) 样本集构建: 选取不同故障位置及不同故障程度谐波减速器声发射信号时频图数据集, 按照一定的比例进行划分, 分别用于训练特征提取网络和测试特征提取网络的性能。采集谐波减速器未知健康状态的数据, 经数据预处理构建验证集。

4) 故障特征提取网络搭建: 引入卷积注意力机制改进残差网络, 提取训练集的深度特征。通过计算模型损失函数值并借助反向传播算法动态调整网络各层参数, 使参数逐步向最小化损失函数的方向不断更新, 直至目标函数达到稳定收敛状态, 从而构建谐波减速器的故障特征提取网络。

5) 多状态定量评估模型构建: 把训练集的样本输入到训练好的特征提取网络中, 将所有分类正确的样本对应的特征保存, 并对特征进行归一化。用正常状态下的特征向量作为训练样本, 训练多 MKSVDD 评估模型, 得到超球体的半径 R , 以正常状态的 MKSVDD 作为基准, 计算某一位置不同故障程度的特征向量到正常 MKSVDD 球心的距离, 通过拟合不同故障程度相对于正常球心的

距离,得到定量评估曲线,引入相对补偿距离,得到多状态同尺度下的定量评估曲线。

6) 健康状态定量评估:将验证集的样本输入到已经训练好的故障特征提取网络中,提取故障数据深度特征,再将特征进行归一化后输入到 MKSVDD 评估模型中,得到待测样本与超球体球心之间的距离 D ,若 $D \leq R$,则表示待测样本为正常状态,否则表明处于故障状态,然后再结合定量评估曲线实现对故障程度的定量分析,得到最终的谐波减速器健康状态定量评估结果。

5 实验验证与结果分析

5.1 实验设备及环境

本研究实验数据均来自如图 6 所示的自建谐波减速器声发射信号采集实验平台。该平台主要由电机控制箱、驱动电机、转矩转速传感器、待测减速器、负载电机、声发射传感器和数据采集仪等部分组成,其测控系统如图 7 所示。




图 6 谐波减速器声发射信号采集实验平台

Fig. 6 Experimental platform for acoustic emission signal acquisition of harmonic reducer

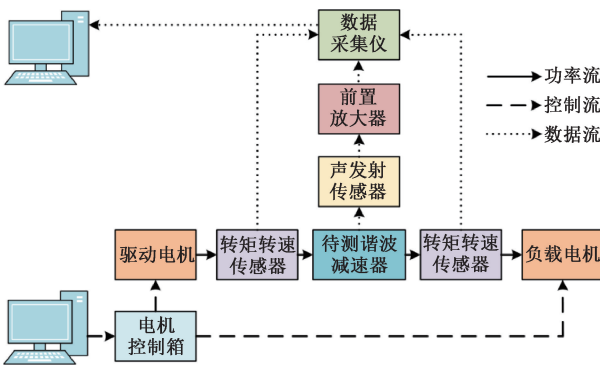


图 7 信号采集实验台测控系统

Fig. 7 Measurement and control system of signal acquisition experimental platform

声发射传感器能够敏锐捕捉机械材料内部的形变,且不易受环境噪声的干扰。在谐波减速器运行过程中,为有效获取待测谐波减速器一个截面内的状态信息,采用美国物理声学公司 (physical acoustics corporation, PAC) 具有高灵敏度、高可靠性的 PAC-R15 声发射传感

器作为传感器。该传感器在 400~1 000 kHz 频段内具有稳定的频率响应特性,从而能够更准确地分析声发射信号中包含的故障频率特征。安装声发射传感器时,使用耦合剂填充传感器和待测谐波减速器之间的空隙,并通过磁夹对声发射传感器加以固定。将声发射传感器部署在谐波减速器 12 点钟方向,以 1 000 kHz 的采样频率采集不同故障位置及不同故障程度的声发射信号,如图 8 所示。




图 8 声发射传感器安装位置

Fig. 8 Installation location of acoustic emission sensor

5.2 声发射信号数据集介绍

以谐波减速器为研究对象,其型号是绿的谐波 LCSG-32-50-C-I。结合其结构特点与实际失效状况,完成了不同故障位置及不同故障程度的加工处理。实验数据涵盖 8 类状态,具体包括:柔性轴承内圈经激光点蚀 1、5、10、15 次的故障类型,柔性轴承外圈经激光点蚀 1、10、15 次的故障类型,以及正常状态(无故障)。为对多状态数据的表述更简洁,8 种状态的表示方法如表 1 所示。以 IR5 和 OR10 为例,前者对应柔性轴承内圈激光点蚀 5 次的故障状态,后者则代表柔性轴承外圈激光点蚀 10 次的故障状态。

表 1 声发射信号数据集内不同状态数据的表示符号
Table 1 Representation symbol of different states data in acoustic emission signal dataset

故障位置	故障程度	表示方法
柔性轴承内圈	点蚀 1 次	IR1
	点蚀 5 次	IR5
	点蚀 10 次	IR10
	点蚀 15 次	IR15
柔性轴承外圈	点蚀 1 次	OR1
	点蚀 10 次	OR10
	点蚀 15 次	OR15
正常状态	无	N

在数据预处理阶段,为保证样本能涵盖完整的故障信息,将谐波减速器柔性轴承转动两圈的信号作为一个

数据集样本,随后通过小波变换生成时频图样本。将表1中谐波减速器声发射信号数据集中,每类400张时频图,按照3:1的比例划分,分别用来训练特征提取网络和测试特征提取网络的性能,并将所有分类正确的样本的深度特征用于训练状态评估模型。

本研究所有实验均在 Windows11 操作系统、CPU 型号 i5-12500H、GPU 型号 NVIDIA GeForce RTX 3050 和配备 16 GB 内存的计算机上进行,搭建深度学习框架的环境为 Python 3.10,PyTorch 2.4。所提方法采用 ReLU (rectified linear unit) 激活函数,训练过程中的迭代次数 epochs 设置为 30,学习率 lr 设置为 0.0005。

5.3 残差网络改进前后对比实验

为了验证卷积注意力模块在谐波减速器故障特征提取时的有效性,利用 t-SNE 算法对改进前后的残差网络所提的特征进行降维操作和可视化分析,结果如图9和10所示。




图9 改进前的 ResNet 特征可视化图

Fig. 9 Feature visualization of the pre-improvement ResNet

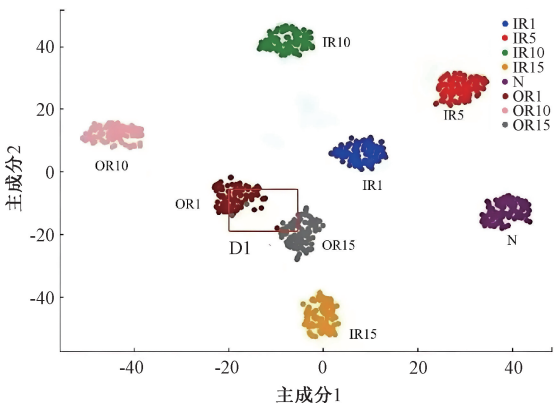


图10 改进后的 ResNet 特征可视化图

Fig. 10 Feature visualization of post-improvement ResNet

通过对比分析图9和10,改进前、后的 ResNet 均存在误分类的样本,但两者的特征降维可视化结果差别较

大。观察图9可知,D3区域内存在部分样本分类错误,在D2和D3区域中还存在样本特征边界不清晰和特征相互重叠的现象。相比之下,图10中卷积注意力机制改进的残差网络只有在D1区域存在少量样本误判,其余各类别特征都能清晰区分。通过上述分析可知,引入卷积注意力机制,可以让残差网络更好地挖掘声发射信号的深度特征,极大提高了模型的特征提取效率。为进一步证实卷积注意力机制改进的残差网络在谐波减速器故障特征提取中的优越性,通过绘制混淆矩阵对比残差网络改进前后的分类效果,分类混淆矩阵如图11和12所示。




图11 改进前 ResNet 混淆矩阵

Fig. 11 Confusion matrix of the pre-improvement ResNet




图12 改进后 ResNet 混淆矩阵


Fig. 12 Confusion matrix of the post-improvement ResNet

通过观察图11和12发现,改进前的 ResNet 对 IR15 和 OR15 这两类故障样本难以区分,同时 OR1 和 N 存在少数错分类样本。引入卷积注意力机制改进后的残差网络提取谐波减速器故障特征,虽然在 OR1 和 OR15 存在极少数错分类样本,但是分类准确率明显提高。综上所述,改进后的残差网络能够着重挖掘图像的显著特征、抑


制无效特征,从而提高谐波减速器的故障诊断准确率。

5.4 振动信号和声发射信号对比实验

为了验证声发射信号相对于振动信号对早期故障更敏感,选取柔性薄壁轴承内圈激光点蚀 1 次对应的振动信号和声发射信号进行分析,对应的包络谱如图 13 所示。



(a) Envelope spectrum of acoustic emission signal



(b) Envelope spectrum of vibration signal

图 13 内圈轻度故障包络谱

Fig. 13 Envelope spectrum of slight inner ring fault

通过分析图 13 可知,当柔性薄壁轴承内圈故障时,振动信号和声发射信号都能够提取故障信息,但是对于点蚀 1 次轻微故障时,声发射信号包络谱中故障特征频率对应的幅值比振动信号更加明显。

为了进一步佐证声发射信号相对于振动信号具有高灵敏度,对早期故障更为敏感的优势,采用改进后的残差网络对谐波减速器的振动信号进行故障诊断,诊断结果如图 14 所示。

通过对比图 12 和 14 发现,故障分类整体准确率提高了 2.4%,其中点蚀 1 次故障的准确率提高了 6%,进一步验证了声发射信号相比振动信号对早期的谐波减速器故障信息更敏感,能够敏锐捕捉故障初期的细微变化。

5.5 谐波减速器健康状态评估模型的建立

构建的 MKSVDD 评估模型需要包含大部分正常样

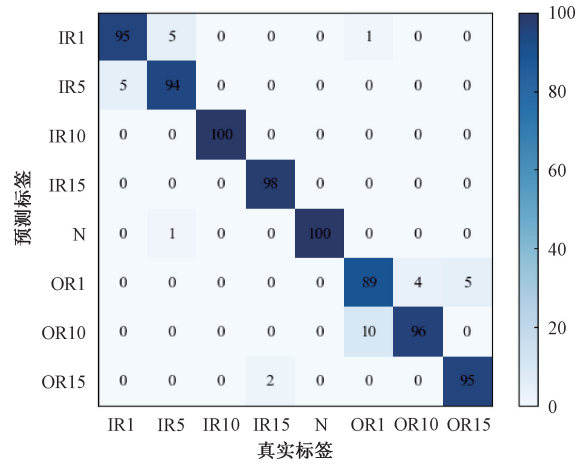


图 14 振动信号分类混淆矩阵

Fig. 14 Confusion matrix of vibration signal classification

本,但不应该有太多的约束,并且核函数的选择需要保证超球面相对稳定。采用网格搜索算法对超参数进行寻优,如图 15 所示。设置权值系数 $\mu = 0.3$,核宽度 $\sigma_1 = 0.9$ 和 $\sigma_2 = 1.5$ 。




图 15 超参数优化过程示意图

Fig. 15 Schematic diagram of the hyper-parameter optimization process

采用正常状态 400 个样本的所有深度特征训练 MKSVDD,分别计算内圈不同故障程度每类 400 个样本相对于正常 MKSVDD 球心的距离,得到距离可视化如图 16 所示。

分析图 16 可知,由于每类样本中有分类错误的样本,得到的相对距离有混叠,会导致后续的评估曲线有较大的误差,不能很好地进行定量分析。因此,将采用每种状态中分类正确的样本进行距离可视化。

将改进的残差网络提取的深度特征与分类的标签对应保存,并对特征进行归一化。用训练集中所有分类正确的正常状态标签对应的特征训练 MKSVDD 评估模型。




图 16 内圈不同故障状态所有样本的相对距离
Fig. 16 Relative distances of all samples for different fault states of the inner ring

以正常 MKSVDD 模型为基准,分别计算内圈不同故障程度的振动信号和声发射信号深度特征到球心的距离,如图 17 和 18 所示。




图 17 声发射信号内圈不同故障程度下的相对距离
Fig. 17 Relative distances under different fault degrees of the inner ring of acoustic emission signal




图 18 振动信号内圈不同故障程度下的相对距离
Fig. 18 Relative distances under different fault degrees of the inner ring of vibration signal

通过观察图 17 和 18 发现,随着内圈故障程度的加深,到正常状态球心的距离呈现明显的阶梯状,说明距离指标可以很好地反映谐波减速器轴承内圈故障程度的变化。同时,声发射信号可以很好地区分正常和点蚀 1 次故障,而振动信号在正常状态和点蚀 1 次故障间无明显界限,进一步表明声发射信号相对振动信号对微弱信号更敏感,更适合用于故障的定量分析。

为了达到定量评估谐波减速器健康状态的目的,首先对内圈的相对距离求取均值,然后针对内圈不同故障程度的距离指标进行二次函数拟合,得到一条光滑的曲线,如图 19 所示。




图 19 谐波减速器内圈定量评估曲线
Fig. 19 Quantitative assessment curve for the inner ring of harmonic reducer

由图 19 可以看出,拟合后的评估曲线呈现单调上升的趋势,故障程度与评估指标呈现正相关,进一步说明 MKSVDD 距离型评估指标对谐波减速器故障程度的变化敏感。评估者可以根据诊断模型判断谐波减速器的故障位置,再根据评估模型计算待测样本的特征向量相对于正常状态球心的距离,然后通过评估曲线判断现阶段减速器的故障程度,实现对谐波减速器运行状态的量化分析。

采用外圈不同故障程度数据进行相同的实验步骤,计算外圈的不同故障程度的特征到球心的距离,如图 20 和 21 所示。

5.6 谐波减速器多状态同尺度定量评估及分析

从图 17~21 中可以看出,对单独某一个故障位置可以区分出不同的故障程度,但是如果将不同故障位置放在一起时,由于声发射信号传播机理导致的一些信息丢失使得谐波减速器的不同故障位置的故障程度无法进行统一评估。

根据谐波减速器柔性薄壁轴承声发射信号的传播机理以及柔性薄壁轴承自身的结构和故障位置,设计




图 20 外圈不同故障程度下的相对距离

Fig. 20 Relative distances under different fault degrees of the outer ring




图 21 谐波减速器外圈定量评估曲线

Fig. 21 Quantitative assessment curve for the outer ring of harmonic reducer

将丢失的信息采用合理的方式进行补偿。由于传感器安装在固定装置上,固定装置包裹着整个外圈,所以认为外圈采集到的信号几乎没有损失。而内圈的信号需要经过外圈后再传递到声发射传感器,所以需要补偿外圈到内圈的相对距离。具体补偿方案如式(16)所示。

$$\begin{cases} d_{IR} = R_{OR} \\ d_{OR} = 0 \end{cases} \quad (16)$$

式中: R_{OR} 为包含外圈所有故障程度样本的超球体相对半径; d_{IR} 为内圈的相对补偿距离; d_{OR} 为外圈的相对补偿距离。

补偿后的多状态评估曲线如图 22 所示,呈现明显的阶梯状,完成相对距离补偿后的曲线可以直观地感受到谐波减速器柔性薄壁轴承运行的多状态信息,便于评估

者在同一尺度下进行可视化评估。




图 22 谐波减速器多状态同尺度定量评估曲线

Fig. 22 Same-scale quantitative assessment curve of harmonic reducer in multiple states

为了验证所提诊断模型和评估曲线的准确性和有效性,选择谐波减速器内圈点蚀 14 次故障和外圈点蚀 5 次故障进行评估实验。首先,对一维故障数据进行连续小波变换得到二维时频图,然后将二维时频图放入已经训练好的故障诊断模型中,得到时频图的深度特征。将提取到的 IR14 和 OR5 故障的特征向量进行归一化,然后放入正常状态 MKSVDD 模型中,计算其到正常状态球心的距离,将对应的距离进行处理和计算均值,内圈和外圈分别加上对应的相对补偿距离,再将得到的评估距离根据多状态评估曲线进行定量分析,评估出故障的点蚀程度,如图 23 所示。




图 23 谐波减速器多状态同尺度定量分析结果

Fig. 23 Diagram of same-scale quantitative analysis results in multiple states of harmonic reducer

观察图 23 可以看出,由模型评估出的故障程度分别为内圈点蚀 13.56 次和外圈点蚀 4.92 次,与实际故障程度内圈点蚀 14 次和外圈点蚀 5 次近似,且最大评估误差不超过 3.2%。由此可以得出,该多状态统一评估曲线能够实现谐波减速器内圈的定量分析,且结果具有一定的准确性和有效性。

6 结 论

针对现有研究一般关注谐波减速器故障位置的诊断,而故障程度以及不同故障位置无法在同一尺度下进行定量分析的问题,提出一种卷积注意力机制改进 ResNet 结合 MKSVDD 的谐波减速器多状态同尺度下的定量评估方法。通过自建实验平台采集到的谐波减速器声发射信号数据集并开展实验验证,得到如下结论:

1) 在现有深度神经网络的基础上,提出卷积注意力机制,增强有用故障信息的比重,忽略冗余信息。通过实时采集的数据进行验证,提出的 CBAM-ResNet 模型相对于原始 ResNet 模型分类准确率更高,证明了 CBAM 机制改进的 ResNet 网络对故障的重要特征更为关注,所提取的特征更符合实际需求。

2) 提出一种基于 MKSVDD 的谐波减速器健康状态定量评估方法。首先构建基于 MKSVDD 模型的距离型指标,采用分类正确的正常状态样本特征训练 MKSVDD,然后计算不同故障程度的样本特征到正常状态球心的距离作为评估指标,从而明显区分不同故障程度,有效实现谐波减速器健康状态定量评估模型的构建。

3) 根据谐波减速器柔性薄壁轴承的结构和信号传播机理,提出相对补偿距离,揭露了谐波减速器在不同故障位置时与声发射信号传递路径之间的表征关系,同时揭示了谐波减速器不同故障位置在同一尺度下的性能退化规律,便于评估者在同一尺度下对处于不同状态的谐波减速器进行定量分析,为谐波减速器的性能评估和故障诊断提供了全新的视角和有效的方法。

实验中已构建谐波减速器多状态同尺度定量评估框架,并利用实测声发射信号对所提框架进行了充分的实验验证,但尚未涉及不同工况下的健康状态定量评估研究,这将是后续研究的重点。

参考文献

- [1] 周萌,李建宇,王昶,等. 多机器人协同围捕方法综述[J]. 自动化学报, 2024, 50(12): 2325-2358.
ZHOU M, LI J Y, WANG CH, et al. Multi-robot cooperative hunting: A survey [J]. Acta Automatica Sinica, 2024, 50(12): 2325-2358.
- [2] 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.
- [3] 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. Reliability

evaluation for precision degradation failure and dependent competing failure of harmonic drives [J]. Journal of Vibration and Shock, 2024, 43(15): 277-287.

- [4] ZHI ZH, LIU L SH, LIU D T, et al. Fault detection of the harmonic reducer based on CNN-LSTM with a novel denoising algorithm [J]. IEEE Sensors Journal, 2021, 22(3): 2572-2581.
- [5] 陈仁祥,张勇,胡小林,等. 多传感器信息深度融合的谐波减速器健康状态评估[J]. 振动与冲击, 2022, 41(7): 139-144,152.
CHEN R X, ZHANG Y, HU X L, et al. Health state evaluation of harmonic reducer based on multi-sensor information deep fusion [J]. Journal of Vibration and Shock, 2022, 41(7): 139-144,152.
- [6] YANG G, ZHONG Y, YANG L, et al. Fault diagnosis of harmonic drive with imbalanced data using generative adversarial network [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [7] 陈仁祥,张勇,胡小林,等. 基于电压信号深度特征学习的谐波减速器健康状态识别[J]. 仪器仪表学报, 2021, 42(7): 234-241.
CHEN R X, ZHANG Y, HU X L, et al. Health state recognition of harmonic reducer based on depth feature learning of voltage signal [J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 234-241.
- [8] 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. A fault diagnosis method for harmonic reducers under different operating conditions based on information fusion subdomain adaptation[J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 60-71.
- [9] 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.
- [10] SUN Y L, KANG SH Q, WANG Y J, et al. Fault diagnosis method for harmonic reducer based on personalized federated aggregation strategy with skip cycle weight[J]. Measurement, 2025, 242: 116275.
- [11] 韩争杰,牛荣军,马子魁,等. 基于注意力机制改进残差神经网络的轴承故障诊断方法[J]. 振动与冲击, 2023, 42(16): 82-91.
HAN ZH J, NIU R J, MA Z K, et al. Bearing fault

- diagnosis methods based on an attentional-mechanism-improved residual neural network[J]. *Journal of Vibration and Shock*, 2023, 42(16): 82-91.
- [12] 康涛, 段蓉凯, 杨磊, 等. 融合多注意力机制的卷积神经网络轴承故障诊断方法[J]. *西安交通大学学报*, 2022, 56(12): 68-77.
- KANG T, DUAN R K, YANG L, et al. Bearing fault diagnosis using convolutional neural network based on a multi-attention mechanism[J]. *Journal of Xi'an Jiaotong University*, 2022, 56(12): 68-77.
- [13] DU X J, LIU B W, GAI J B, et al. Gear fault diagnosis based on small channel convolutional neural network under multiscale fusion attention mechanism[J]. *Quality and Reliability Engineering International*, 2024, 40(8): 4147-4165.
- [14] LU K J, CHEN CH, WANG T, et al. Fault diagnosis of industrial robot based on dual-module attention convolutional neural network[J]. *Autonomous Intelligent Systems*, 2022, 2(1): 1-12.
- [15] 路近, 王志国, 刘飞. 基于 STFT-ECA-ResNet18 网络模型的滚动轴承变负载故障诊断[J]. *噪声与振动控制*, 2024, 44(2): 122-128.
- LU J, WANG ZH G, LIU F. Rolling bearing variable load fault diagnosis based on STFT-ECA-ResNet18 network model[J]. *Noise and Vibration Control*, 2024, 44(2): 122-128.
- [16] XU Y D, CHEN Y J, ZHANG H CH, et al. Global contextual feature aggregation networks with multiscale attention mechanism for mechanical fault diagnosis under non-stationary conditions[J]. *Mechanical Systems and Signal Processing*, 2023, 203: 110724.
- [17] 尹文豪. 基于融合概率建模与边界距离的滚动轴承性能退化评估[D]. 南昌: 华东交通大学, 2021: 4-5.
- YIN W H. Performance degradation evaluation of rolling bearings based on fusion probabilistic modeling and boundary distance[D]. Nanchang: East China Jiaotong University, 2021: 4-5.
- [18] 陈鹏, 赵小强. 基于 GLNPE-SVDD 的滚动轴承性能退化评估方法[J]. *华中科技大学学报(自然科学版)*, 2021, 49(1): 12-16.
- CHEN P, ZHAO X Q. Performance degradation evaluation method of rolling bearing based on GLNPE-SVDD[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2021, 49(1): 12-16.
- [19] XIN H W, ZHANG H D, YANG Y J, et al. Evaluation of rolling bearing performance degradation based on comprehensive index reduction and SVDD[J]. *Machines*, 2022, 10(8): 677.
- [20] 程道来, 魏婷婷, 潘玉娜, 等. 基于 DBN-SVDD 的滚动轴承性能退化评估方法[J]. *轴承*, 2021(10): 41-46.
- CHENG D L, WEI T T, PAN Y N, et al. Performance degradation assessment method for rolling bearings based on DBN-SVDD[J]. *Bearing*, 2021(10): 41-46.
- [21] 孙曙光, 张婷婷, 王景芹, 等. 基于连续小波变换和 MTL-SEResNet 的断路器故障程度评估[J]. *仪器仪表学报*, 2022, 43(6): 162-173.
- SUN SH G, ZHANG T T, WANG J Q, et al. Fault degree evaluation of circuit breaker based on continuous wavelet transform and MTL-SEResNet[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(6): 162-173.
- [22] 康玉祥, 陈果, 尉询楷, 等. 深度残差对冲网络及其在滚动轴承故障诊断中的应用[J]. *航空学报*, 2022, 43(8): 63-74.
- KANG Y X, CHEN G, WEI X K, et al. Deep residual heging network and its application in fault diagnosis of rolling bearings[J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(8): 63-74.
- [23] 魏秀业, 程海吉, 贺妍, 等. 基于特征融合与 ResNet 的行星齿轮箱故障诊断[J]. *电子测量与仪器学报*, 2022, 36(5): 213-222.
- WEI X Y, CHENG H J, HE Y, et al. Fault diagnosis of planetary gearboxes based on feature fusion and ResNet[J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(5): 213-222.
- [24] 秦国浩, 张楷, 丁昆, 等. 动态宽卷积残差网络的轴承故障诊断方法[J]. *中国机械工程*, 2023, 34(18): 2212-2221.
- QIN G H, ZHANG K, DING K, et al. Dynamic wide convolutional residual network for bearing fault diagnosis method[J]. *China Mechanical Engineering*, 2023, 34(18): 2212-2221.
- [25] 王翰伟, 许昕, 潘宏侠, 等. 基于 GADF 和 HWP-CBAM-ResNet 的弧齿锥齿轮箱故障诊断[J]. *电子测量技术*, 2024, 47(21): 100-110.
- WANG H W, XU X, PAN H X, et al. Fault diagnosis for spiral bevel gearboxes based on GADF and HWP-CBAM-ResNet[J]. *Electronic Measurement Technology*,

2024, 47(21): 100-110.

- [26] PANG Y N, CHENG D L, WEI T T, et al. Rolling bearing performance degradation assessment based on deep belief network and improved support vector data description [J]. *Mechanical Systems and Signal Processing*, 2022, 181: 109458.

作者简介



孙宇林, 2017年于绥化学院获得学士学位, 2022年于天津理工大学获得硕士学位, 现为哈尔滨理工大学博士研究生。主要研究方向为故障诊断、状态评估与预测技术、联邦学习。

E-mail: 2210603076@stu.hrbust.edu.cn

Sun Yulin received his B. Sc. degree from Suihua University in 2017, and received his M. Sc. degree from Tianjin University of Technology in 2022. He is currently pursuing his Ph. D. degree at Harbin University of Science and Technology. His main research interests include fault diagnosis, state evaluation and prediction technology and federated learning.



罗双, 2022年于南京工程学院获得学士学位, 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: lshuang0428@163.com

Luo Shuang received his B. Sc. degree from Nanjing Institute of Technology in 2022. He is currently 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. and M. Sc. degrees from Harbin University of Science and Technology in 2004 and 2007, respectively, and his Ph. D. degree from Belarusian State University in 2011. He is now 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.