

DOI: 10.19650/j.cnki.cjsi.J2514616

油液磨粒感应电压信号可解释智能识别方法研究*

罗久飞¹, 康枫佳¹, 邓云春¹, 宋鸿正², 尹爱军²

(1. 重庆邮电大学集成电路学院 重庆 400065; 2. 重庆大学机械与运载学院 重庆 400044)

摘要: 装备服役状态实时监测与评估是保障大型复杂机电系统稳定运行的关键环节。电感式磨粒传感器通过电磁感应检测润滑油中的磨损颗粒, 为机械关键部件的磨损评估提供可靠依据, 已在大型机械装备维护中得到广泛应用。然而, 磨粒诱发的感应电压信号通常较弱, 在干扰影响下难以通过人工特征提取方法准确识别, 限制了电感式油液磨粒传感器的识别精度及泛化能力。为此, 提出了一种油液磨粒信号智能识别方法, 首先, 利用磨粒信号在多尺度滤波下的形态稳定特性, 构建多尺度滤波特征, 以刻画磨粒事件的关键几何轮廓与能量分布, 为后续深度学习提供具有物理意义的输入表征。随后, 设计并行卷积模块, 对各尺度特征进行分支式深度卷积建模, 并引入改进的融合注意力模块, 在通道与时间维度上自适应重标定特征权重, 突出磨粒敏感成分、抑制复杂背景干扰。最后, 将重构后的多尺度特征序列输入 Vision Transformer, 通过自注意力机制捕获长程依赖关系与跨尺度相关性, 从而在强干扰和低信噪比条件下实现对磨粒感应电压信号的精准辨识。实验结果表明, 所提出的模型在三线圈传感器与高梯度静磁场传感器的数据集上均取得优异表现, 干扰排除率、磨粒识别率与识别准确率分别达到 99.72%、98.94% 和 99.44%, 在 -5~0 dB 的低信噪比环境下对于磨粒信号的检测效果仍优于传统算法。

关键词: 磨粒检测; 感应式磨粒传感器; 神经网络; 注意力机制

中图分类号: TP206+.3 TP183 TH117 **文献标识码:** A **国家标准学科分类代码:** 510.40

An interpretable intelligent recognition method for voltage signals induced by wear debris in lubricating oil

Luo Jiufei¹, Kang Fengjia¹, Deng Yunchun¹, Song Hongzheng², Yin Aijun²

(1. School of Integrated Circuits, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Monitoring and evaluating the in-service condition of equipment in real time is essential for maintaining the stable operation of large-scale complex electromechanical systems. Inductive oil debris sensors detect wear particles in lubricating oil via electromagnetic induction, providing a reliable basis for assessing the wear condition of critical mechanical components, and have been widely applied in the maintenance of large-scale mechanical equipment. However, the induced voltage signals generated by debris are usually weak and are difficult to identify accurately by manual feature extraction under the influence of various interferences, which limits the identification accuracy and generalization capability of inductive oil debris sensors. To address this issue, this paper proposes an intelligent recognition method for oil debris signals, referred to as PCatten. Firstly, the morphological stability of debris-induced signals under multiscale filtering is exploited to construct multiscale filtering features, which characterize the key geometric profiles and energy distribution of debris events and provide physically meaningful input representations for subsequent deep learning. Subsequently, a parallel convolution module is designed to perform branch-wise deep convolutional modeling of features at different scales, and an improved fusion attention module is introduced to adaptively recalibrate feature weights along the channel and temporal dimensions, thereby highlighting debris-sensitive components and suppressing complex background interference. Finally, the reconstructed multiscale feature sequence is fed into a Vision Transformer, which captures long-range dependencies and cross-scale correlations through the self-attention mechanism, enabling accurate discrimination of debris-induced voltage signals under strong interference and low signal-to-noise ratios. Experimental results demonstrate that the proposed model achieves excellent performance on both three-coil sensor dataset and high-gradient static magnetic field sensor dataset, the interference elimination rate, debris identification rate, and debris identification accuracy are

收稿日期: 2025-10-23 Received Date: 2025-10-23

* 基金项目: 国家重点研发计划项目(2024YFB3213102)、重庆市教育委员会科学技术研究项目(KJZD-K202400609)资助

99.72%, 98.94%, and 99.44%, respectively, and the proposed method still exhibits superior debris-detection performance compared with traditional algorithms under low signal-to-noise ratios ranging from -5 to 0 dB.

Keywords: debris detection; inductive debris sensor; neural network; attention mechanism

0 引言

感应式磨粒传感器因其结构简单、不侵占油道、高时效等特性^[1],是当前最具有潜力的油液磨粒在线监测技术路径之一。近年来国内外相关研究者开发了不同磁场结构的磨粒传感器,已成为航空发动机^[2]、船舶动力系统和风电齿轮箱等关键设备故障预测与健康管理的感知来源^[3]。然而,受限于机械装备作业环境的复杂性和严苛性,感应式磨粒传感器易受电路噪声、空间电磁波以及机械振动等因素的干扰,导致微弱磨粒感应电压极易失真,成为制约传感器检测精度和量化分析性能的关键因素^[3-4]。

通过采用一系列噪声抑制和特征辨识的信号处理方法,可以有效提升感应式磨粒传感器的检测性能。目前,磨粒感应电压信号处理方法主要可归纳为基于信号成分分解类降噪方法^[5-6]和基于几何形态特征学的阈值滤波法^[4,7-8],二者在具有充分先验知识的前提下均取得良好的信噪比(signal to noise ratio, SNR)提升效果。然而,分解类方法极度依赖关键尺度成分的提取,缺乏对磨粒信号特征的选择性和特异性,在分解梯度不满足精度要求的前提下难以权衡噪声排除与磨粒信号关键特征保护。阈值滤波方法通常基于多维二值化判别指标,对传感器结构参数、实际部署环境参量估计等提出极高要求,难以具备场景泛用性。

深度学习技术在机械设备故障诊断与预测任务中已展现高超能力^[9]。相比于传统信号处理方法,深度学习在复杂隐含特征学习能力等方面具有人工特征提取算法不可比拟的优势^[10]。作为典型的网络结构,卷积神经网络(convolutional neural network, CNN)及其改进模型具有强大的高维特征提取能力,在结构损伤检测^[11]、旋转机械故障诊断^[12]以及损伤定位^[13]等信息处理领域取得了显著成果。Wang等^[14]提出了一种自适应去噪卷积神经网络,在残差收缩网络基础上设计自适应去噪单元,在端到端训练中同时完成特征提取与去噪。Li等^[15]提出了一种自适应多尺度全卷积网络,从卷积感受野和多尺度建模角度提升CNN在噪声环境中的特征提取能力。然而在实际应用中,CNN通常被视为具有大量复杂参数的黑盒模型,难以建立故障信号与所提取的高维特征之间的明确关系^[16]。因此,可解释性缺失造成的识别结果可信度不足仍是制约CNN在工业实际应用中的关键问题。

为提高智能故障诊断的可解释性,一方面研究者尝

试将目标信号机制融入神经网络模型,徐大伟等^[17]提出了一种基于物理信息嵌入的故障诊断网络,在全卷积网络中显式引入绳索张力与关节角度的力学约束关系,通过多目标损失函数融合物理规律与数据特征,实现了物理先验与深度学习的协同建模,显著提升了模型的诊断精度与物理可解释性。Jia等^[18]提出了一种物理信息驱动的无监督域自适应框架,结合轴承特征频率与谱能量构建物理伪标签和物理损失,将物理约束嵌入源域模型训练,并在目标域通过物理信息与谱聚类联合生成硬/软伪标签,配合伪标签置信度动态增强策略,实现跨机器高鲁棒诊断并提升模型的物理可解释性。另一方面,研究者结合注意力机制来提升神经网络模型对关键特征的感知与表征能力,乔卉卉等^[19]以注意力机制为核心,提出了一种多源信息融合网络,将注意力分别作用于时间-通道特征和多传感器模态上,在变转速、变负载条件下显著提升了特征判别性和诊断鲁棒性。小波变换作为一种典型的信号处理技术,在智能故障诊断领域也被用于提升模型的可解释性。王俊等^[20]提出了一种小波核编码的脉冲卷积神经网络模型,将小波核卷积嵌入神经网络前端,以小波核提取轴承振动信号的多尺度物理特征,通过脉冲神经元实现特征的时序脉冲编码,构建兼具物理与生物可解释性的特征表示。Jiang等^[21]提出了一种多小波核卷积神经网络,通过多小波核融合构建可解释的卷积特征表示,实现良好的诊断性能。Wang等^[22]提出多层小波注意力卷积神经网络,通过在CNN中交替嵌入离散小波注意力层与卷积层,形成可解释的多分辨特征链,该方法能够在强噪声环境下稳定提取故障相关频带特征,实现高鲁棒性诊断。

受深度学习在故障诊断领域中成功应用的启发,本研究尝试构建一种智能的磨粒识别方法,以克服传统磨粒检测方法复杂的处理流程,实现磨粒特征的自动提取与识别,用于设备的智能健康管理。现有研究表明,当前深度学习方法在磨粒信号识别中的应用仍面临如下难点。一方面,磨粒的准确识别主要依赖于磨粒信号与干扰成分在时域上的差异,而CNN结构单一,在短时一维信号上的表达能力有限,难以在强噪声干扰下避免磨粒信号的漏检,同时一些具有类似波形特征的高能脉冲信号易被误识为磨粒,导致假磨粒预测数量增加,影响磨粒识别方法的可靠性。另一方面,磨粒诱发信号具有短时、非周期的特性,传统单一的CNN融合注意力机制后仍难以利用高维时频特征形成可解释的判别依据,限制了方法的可信度。

针对上述问题,本研究融合磨粒感应电压信号的几何形态特征,提出了一种可解释的并行卷积注意力网络(parallel convolution attention network, PCatten)。首先,通过磨粒信号频谱特性构造连续的低通滤波器提取内含几何形态稳定性的多尺度特征向量。然后,提出并行卷积模块将多尺度特征向量依次深度编码为高维特征图,实现在保持形态特征稳定性下多尺度特征向量隐含特征的有效提取。最后引入视觉 Transformer (vision Transformer, ViT)层,结合并行卷积后多尺度特征向量重构结果的相关性度量,实现复杂干扰下可解释的磨粒感应电压信号精准辨识。通过两个典型电感式传感器获取两个不同的实验数据集,并结合实验数据与数学模型仿真,验证了所提出方法的有效性与鲁棒性,为复杂工况下磨粒信号的准确识别提供了新的思路。

1 磨粒信号的几何形态特征

1.1 感应式磨粒传感器的检测信号

对于典型的三线圈感应式磨粒传感器,其输出磨粒感应电压信号的几何形态通常被近似为单周期正弦信号。磨粒穿过激励与感应线圈组时,会扰动线圈间的磁场分布,改变局部磁场强度与分布形态,引发感应线圈中心位置磁通量变化,感应线圈中的时变磁场会在其两端感应出电压^[23],即:

$$E(t) = N_2 \frac{d}{dt} \left[\frac{\mu_0 \pi r^2 N_1 l_c \Delta I}{2l((l+l_0-vt)^2+r^2)^{3/2}} \right] \quad (1)$$

其中, N_1, N_2 分别表示激励线圈和感应线圈的匝数, l 表示激励线圈长度, l_0 表示两激励线圈的中心距离, r 表示线圈半径, l_c 表示磨粒长度, μ_0 表示真空磁导率, v 表示在匀速运动假设下的磨粒运动速度。电流量变化 $\Delta I = [L_c / (L_c + L_0)] I$, 其中 I 为激励电流, L_0 表示磨粒所覆盖的激励线圈对应段在无磨粒条件下的原始电感, L_c 表示磨粒进入后由于局部磁导率变化引起磁通量增加所导致的附加电感增量。

由于油液流速的限制,磨粒信号的中心频率通常较低,可近似估算为 $f_d \approx v_l / L_{zone}$, 其中 v_l 表示油液流速, L_{zone} 表示传感器的检测区域长度^[6]。因此,磨粒信号的估算持续时间可定义为 $\hat{\varepsilon} = f_s / f_d$ 。

考虑到传感器所在区域内机电系统存在较强的电磁谐波干扰,首先引入谐波抑制策略^[3],根据估计谐波频谱参数初步提升传感器输出信号的 SNR。处理后的序列的 $[y(0), y(1), \dots, y(n), \dots, y(N_0 - 1)]$ 数值表达可依据文献^[3]中的数学模型,如式(2)所示。

$$y(n) = \psi(n; A, \tau, \varepsilon) + r(n) \quad (2)$$

其中, A 表示幅值因子, ψ 表示简化磨粒特征信号理论模型, τ 表示信号发生时刻, ε 表示持续时间, $r(n)$ 表示

残余干扰分量。

1.2 磨粒感应电压信号的几何稳定性

信号 $y(n)$ 的频谱可表示为:

$$Y(f) = F(\psi(n; A, \tau, \varepsilon) + r(n)) = D(f) + R(f) \quad (3)$$

其中, $F(\cdot)$ 表示离散傅里叶变换, $D(f)$ 与 $R(f)$ 分别是磨粒信号和干扰分量在频域的表达式。假设对信号 $y(n)$ 施加一个截止频率为 f_c 的低通滤波器,则滤波后的结果可表示为:

$$\hat{Y}(f; f_c) = H(f; f_c) D(f) + H(f; f_c) R(f) \quad (4)$$

其中, $H(f; f_c)$ 表示低通滤波器的频率响应。相较于干扰项 $R(f)$, 磨粒信号 $D(f)$ 通常呈现出一定的几何形态特征,并集中分布在以中心频率 f_d 的有限频带范围^[3]。当 $\alpha f_d < f_c$ 且 α 为带宽扩展系数时,可认为 $D(f) H(f; f_c) \approx D(f)$, 从而忽略此处的近似误差。滤波后的时域信号可近似表示为:

$$\hat{y}(n; f_c) \approx F^{-1}(D(f)) + F^{-1}(H(f; f_c) R(f)) \quad (5)$$

其中, $F^{-1}(\cdot)$ 表示傅里叶逆变换(inverse Fourier transform, IFT)。由此可知 $F^{-1}(D(f)) \approx \psi(n; A, \tau, \varepsilon)$ 但 $F^{-1}(H(f; f_c) R(f)) = \hat{r}(n; f_c) \neq r(n)$, 因为残余干扰能量在频域中呈随机分布。随着滤波频带收缩,干扰项的频域形态会持续变化,而磨粒信号的几何形态保持稳定。

如图1所示,通过在不同滤波尺度下对信号向量施加适当的映射函数,局部特征将随着磨粒信号的出现呈现稳定性。因此,可采用相同的编码器将多尺度滤波特征(multiscale filtering features, MFF)映射至高维空间,并基于重构 MFF 的时域特性和相似性,实现对磨粒信号的准确识别。

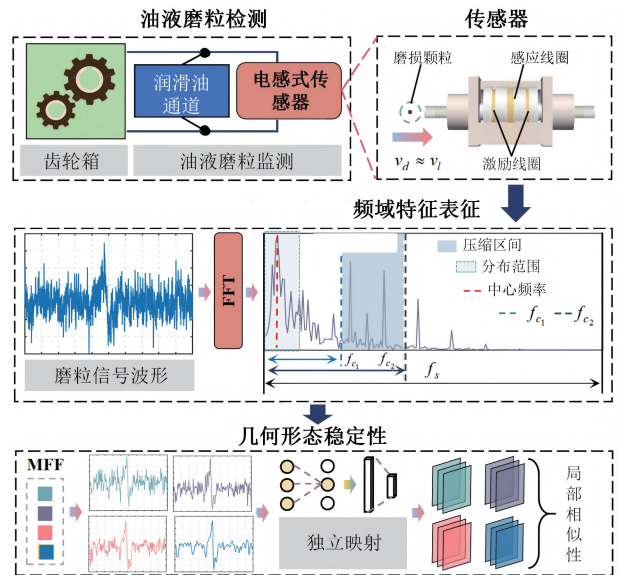


图1 磨粒特征几何形态稳定性示意图

Fig. 1 The illustration for geometric morphological stability of debris signatures

为最大程度保护磨粒特征的完整性,在多尺度滤波过程中设置4个不同的截止频率,分别为 $f_{c_1} = 3f_d$ 、 $f_{c_2} = 2.5f_d$ 、 $f_{c_3} = 2f_d$ 和 $f_{c_4} = 1.5f_d$,信号 y 的多尺度滤波结果可表示为:

$$\tilde{\mathbf{Y}} = \{\tilde{\mathbf{y}}_{f_{c_1}}, \tilde{\mathbf{y}}_{f_{c_2}}, \tilde{\mathbf{y}}_{f_{c_3}}, \tilde{\mathbf{y}}_{f_{c_4}}\} \quad (6)$$

使用窗口长度为 N ,步长为 $N/2$ 的滑动窗口按序列进行分割,形成 U 组MFF样本,可表示为:

$$\mathbf{X}_u = \{\mathbf{x}_{f_{c_1,u}}, \mathbf{x}_{f_{c_2,u}}, \mathbf{x}_{f_{c_3,u}}, \mathbf{x}_{f_{c_4,u}}\} \quad (7)$$

其中, $u = 1, 2, \dots, U$ 为MFF样本序号且 $\mathbf{X}_u \in \mathbf{R}^{4 \times N}$ 。最终,为消除直流分量对模型判别性能的影响,对每组样本进行偏置消除,可表示为:

$$\tilde{\mathbf{X}}_u(j) = \mathbf{X}_u(j) - \bar{\mathbf{X}}_u(j) \quad (8)$$

其中, j 表示 \mathbf{X}_u 中第 j 个实例, $\bar{\mathbf{X}}_u(j)$ 为其对应的均值向量。

2 基于可解释融合网络的磨粒信号辨识

2.1 融合注意力模块

通道注意力与空间注意力机制能够根据输出特征图中的全局与局部信息赋予不同的注意力权重,突出关键特征,增强模型对不同特征的敏感性^[24]。磨粒检测任务中的磨粒诱发信号具有非平稳特性且易受噪声干扰,仅关注平均池化与最大池可能导致在特征聚合过程中表征维度单一,限制模型对判别性特征的捕获能力。为此,提出了一种改进的融合注意力模块(fusion attention module, FAM),为特征图中的注意力权重分配提供更为全面的依据,FAM模块的基本结构如图2所示。

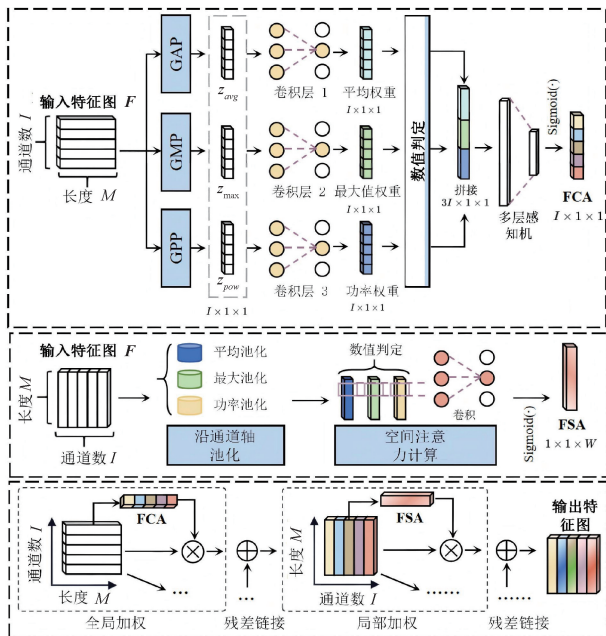


图2 FAM基本结构

Fig. 2 Basic structure of the FAM

信号功率是表征磨粒信号时序模式的重要指标,本文将全局功率池机制^[25]引入注意力机制^[24],明确地建模特征表示间的相互依赖关系。假设 $\mathbf{F} = [f_1, f_2, \dots, f_i, \dots, f_I]$ 是具有 I 个通道的卷积层的输出特征图,且 $f_i \in \mathbf{R}^{1 \times M}$,全局信息计算公式为:

$$\begin{cases} z_{avg} = \text{Gap}(\mathbf{F}) = \left[\frac{1}{M} \sum_{m=1}^M f_i(m) \right], & i = 1, 2, \dots, I \\ z_{max} = \text{Gmp}(\mathbf{F}) = [\max(f_i)], & i = 1, 2, \dots, I \\ z_{pow} = \text{Gpp}(\mathbf{F}) = \left[\sum_{m=1}^M (f_i(m))^2 \right], & i = 1, 2, \dots, I \end{cases} \quad (9)$$

其中, $\text{Gap}(\cdot)$ 、 $\text{Gmp}(\cdot)$ 和 $\text{Gpp}(\cdot)$ 分别表示平均池化、最大池化、功率池化。每一信息向量的数值进一步由标准差稳定性决定。对于任意 $z \in \mathbf{R}^{1 \times I}$,标准差稳定性定义为:

$$\lambda = I \log \sqrt{\frac{1}{I} \sum_{i=1}^I (z(i) - \bar{z})^2} \quad (10)$$

其中, \bar{z} 表示平均值。使用Softmax计算各向量的权重,可表示为:

$$\tilde{z} = z \cdot \frac{\exp(\lambda)}{\sum_{\gamma=1}^Q \exp(\lambda_{\gamma})} \quad (11)$$

其中, $\gamma = 1, 2, \dots, Q$,且 Q 为信息向量的总数量。

此后, z_{avg} 、 z_{max} 、 z_{pow} 分别转换带权形式的 \tilde{z}_{avg} 、 \tilde{z}_{max} 、 \tilde{z}_{pow} 。通过3个卷积核大小为 κ_c 的独立卷积层,将向量映射为通道权重,通过向量拼接的方式得到融合通道信息向量,即:

$$z_{con} = C(\tilde{z}_{avg}, \kappa_c) \oplus C(\tilde{z}_{max}, \kappa_c) \oplus C(\tilde{z}_{pow}, \kappa_c) \quad (12)$$

其中, $C(\cdot)$ 表示卷积运算, \oplus 表示向量拼接。随后,权重矩阵 $z_{con} \in \mathbf{R}^{1 \times 3I}$ 被输入至全连接层,并通过Sigmoid激活函数 $\delta(\cdot)$ 得到最终的融合通道注意力(fusion channel attention, FCA),即:

$$\mathbf{g}_{cam} = \delta(\mathbf{W}_c \cdot z_{con} + \beta_c) \quad (13)$$

其中, β_c 为偏置项且 $\mathbf{W}_c \in \mathbf{R}^{1 \times 3I}$ 。通过将原始输出特征图 \mathbf{F} 与 \mathbf{g}_{cam} 相乘,以增强具有判别能力的特征图区域,同时加入残差连接避免深层特征响应的过度衰减,可表示为:

$$\mathbf{F}_{cw} = \mathbf{F} \cdot \mathbf{g}_{cam} + \mathbf{F} \quad (14)$$

融合空间注意力(fusion spatial attention, FSA)用于对有用的局部信息进行加权处理,以增强局部显著区域的表达。采用平均池化、最大池化与功率池化来获取相应的权重 \tilde{v}_{avg} 、 \tilde{v}_{max} 和 \tilde{v}_{pow} ,同时使用卷积核大小为 $\kappa_s = 7$ 的卷积运算将拼接后的向量转换为FSA:

$$\mathbf{g}_{sam} = \delta(C_s([\tilde{v}_{avg}; \tilde{v}_{max}; \tilde{v}_{pow}], \kappa_s)), \mathbf{g}_{sam} \in \mathbf{R}^{1 \times M} \quad (15)$$

最后运用 \mathbf{g}_{sam} 对各通道进行逐元素加权:

$$\mathbf{F}_{sw} = [\mathbf{F}_{cw}(i) \odot \mathbf{g}_{sam} + \mathbf{F}_{cw}(i)], i = 1, 2, \dots, I \quad (16)$$

其中, $\mathbf{F}_{cw}(i) \in \mathbf{R}^{1 \times M}$ 表示 \mathbf{F}_{cw} 的第 i 个特征图, \odot 表示 Hadamard 积。

2.2 模型架构设计

PCatten 的基本结构如图 3 所示, 主要由卷积编码 (convolution encoding, CE) 层、稳定性加权层以及 ViT 层 3 个模块组成。

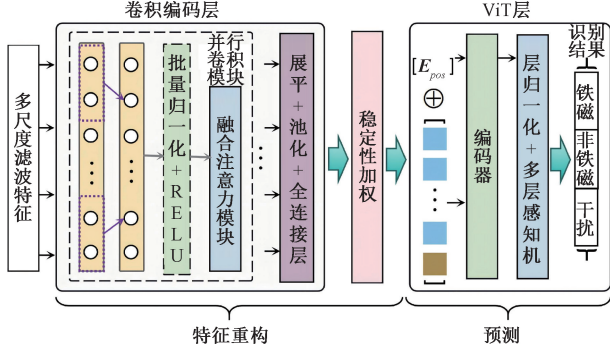


图3 PCatten 总体结构框架

Fig. 3 Overall architecture of the PCatten

CE 层的详细结构如表 1 所示, 包含由 5 个卷积操作与 FAM 模块组成的平行卷积模块, 以及由池化与线性映射组成的重构模块, 用于实现维度压缩与特征融合。

表 1 卷积编码层参数

Table 1 The parameters of CE layer

网络层	结构	参数	输出
平行卷积层	Conv/BN/RL/FAM	$L=16, k=15$	$16, N$
	Conv/BN/RL/FAM	$L=32, k=9$	$32, N$
	Conv/BN/RL/FAM	$L=64, k=5$	$64, N$
	Conv/BN/RL/FAM	$L=128, k=3$	$128, N$
	Conv/BN/RL/FAM	$L=256, k=3$	$256, N$
展平层			$256 \times N$
池化层	最大池化	$k=4, p=4$	$64 \times N$
	平均池化	$k=4, p=4$	$16 \times N$
全连接层			$1 \times N$

模型首先将原始多尺度滤波特征映射至高维特征空间中。对于给定输入 $\tilde{\mathbf{X}}_u \in \mathbf{R}^{4 \times N}$, 平行卷积层的输出可表示为:

$$\mathbf{H}_u = \{\mathbf{h}_{u,1}, \mathbf{h}_{u,2}, \mathbf{h}_{u,3}, \mathbf{h}_{u,4}\} \quad (17)$$

其中, $\mathbf{h}_{u,\epsilon} \in \mathbf{R}^{L_s \times N}$, ϵ 表示实例的特征顺序编号。将每个特征图展平后, 分别通过最大池化和平均池化以降低参数维度, 再通过全连接层得到重构特征向量 $\vec{\mathbf{x}}_{u,\epsilon} \in \mathbf{R}^{1 \times N}$, 可表示为:

$$\vec{\mathbf{X}}_u = \{\vec{\mathbf{x}}_{u,1}, \vec{\mathbf{x}}_{u,2}, \vec{\mathbf{x}}_{u,3}, \vec{\mathbf{x}}_{u,4}\} \quad (18)$$

FAM 模块的重校准用于区分 $\vec{\mathbf{X}}_u$ 中各实例的重要性, 同时反映重构特征的局部特性和时间稳定性, 加权过程可以表示为:

$$\hat{\mathbf{X}}_u = \Omega_c(\Omega_s(\vec{\mathbf{X}}_u)) \quad (19)$$

其中, $\Omega_s(\cdot)$ 和 $\Omega_c(\cdot)$ 分别表示 FSA 和 FCA 重校准操作。为有效捕获 $\hat{\mathbf{X}}_u$ 的全局关系并建模局部特征之间的远距离依赖关系, 本文引入 ViT 层^[26], 其由嵌入层、Transformer 编码器和多层感知机 (multilayer perceptron, MLP) 组成^[27]。

将一个可学习的嵌入向量 $\boldsymbol{\eta}_u \in \mathbf{R}^{1 \times N}$ 添加到权重特征, 同时引入位置编码 $\mathbf{E}_{pos} \in \mathbf{R}^{(J+1) \times N}$, 使用正弦/余弦生成位置嵌入, 为所有实例添加位置信息^[27], 如式 (20) 所示。

$$\boldsymbol{\zeta} = Te([\boldsymbol{\eta}_u; \hat{\mathbf{X}}_u] + \mathbf{E}_{pos}), \mathbf{E}_{pos} \in \mathbf{R}^{(J+1) \times N} \quad (20)$$

其中, $Te(\cdot)$ 表示 Transformer 编码操作。提取输出向量 $\boldsymbol{\zeta}$ 中的分类标识符 $\boldsymbol{\eta}'_u$, 并通过 MLP 转换为分类向量 $\hat{\boldsymbol{\theta}}_u$, 可获得第 u 个样本的预测结果。最终, 模型训练通过优化交叉熵损失函数 ℓ_{CE} 进行监督, 损失定义为:

$$\ell_{CE} = -\frac{1}{U} \sum_{u=1}^U \boldsymbol{\theta}_u \log(\hat{\boldsymbol{\theta}}_u) \quad (21)$$

其中, $\boldsymbol{\theta}_u$ 表示第 u 个样本的真实标签。

2.3 基于形态稳定性的辨识网络

对于参数恒定的卷积神经网络, 输入向量与模型重构特征在样本类别层面存在特定对应的关系。因此即使在具体数值上存在差异, 由于原始信号保持几何形态稳定性, PCatten 模型对磨粒特征 MFF 的重构结果在时域上仍会表现出显著的相似性。相比之下, 干扰分量在带宽收缩过程中局部形态会随机波动, 重构 MFF 难以体现出相似性, 与磨粒信号的局部时域特征显著不同。

为了感知磨粒特征识别的判别依据, 对式 (18) 中得到的重构 MFF 样本进行归一化处理与可视化分析。利用皮尔逊相关系数^[3], 对归一化实例 $\hat{\mathbf{X}}_u$ 中任意两个样本进行相关性计算, 构建特征相关性矩阵以量化分析信号特征的一致性, 表达式如式 (22) 所示。

$$\text{Similar}(\hat{\mathbf{X}}_u) = \begin{bmatrix} \chi(\hat{\mathbf{x}}_{u,1}, \hat{\mathbf{x}}_{u,1}) & \cdots & \chi(\hat{\mathbf{x}}_{u,1}, \hat{\mathbf{x}}_{u,4}) \\ \vdots & \ddots & \vdots \\ \chi(\hat{\mathbf{x}}_{u,4}, \hat{\mathbf{x}}_{u,1}) & \cdots & \chi(\hat{\mathbf{x}}_{u,4}, \hat{\mathbf{x}}_{u,4}) \end{bmatrix} \quad (22)$$

其中, $\hat{\mathbf{x}}_{u,\epsilon}$ 表示归一化后的重构样本, $\chi(\cdot)$ 表示表示相似度计算函数。最终, 完整的辨识方法流程步骤为:

- 1) 采集感应式磨粒检测传感器输出电压;
- 2) 对原始信号进行多尺度滤波, 构造多尺度滤波特征 MFF;
- 3) 将 MFF 各尺度片段输入平行卷积模, 提取高维局

部特征;

- 4) 引入 FAM 模块对多尺度特征进行加权重标定;
- 5) 将输出特征序列输入 ViT 层, 输出磨粒干扰分类结果;
- 6) 根据预测标签实现磨粒信号识别与计数。

3 实验验证及结果分析

3.1 实验准备

如图 4 所示, 搭建了一套实验平台, 用于采集三线圈传感器^[22]的检测信号, 并采用与三线圈传感器具有相似输出信号特征的高梯度传感器^[28]进行交叉验证。

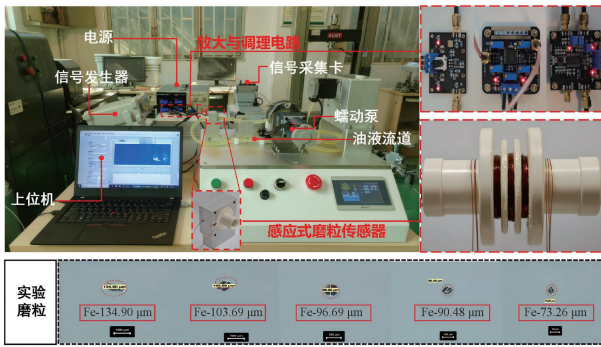


图 4 磨粒检测实验平台

Fig. 4 Debris detection experimental platform

整个实验平台主要包括电感式磨粒传感器、可调蠕动泵、直流电源、信号发生器、放大与调理电路、信号采集卡、上位机等。蠕动泵将含有金属磨粒的油液循环注入油液流动, 形成封闭回路, 保证稳定流动。实验中采用的铁磁性金属磨粒直径不超过 200 μm , 铜磨粒直径不超过 500 μm , 采样频率 f_s 预设为 5 000, 采样时间为 30 s。

对传感器历史采集信号进行预处理, 采用滑动窗口进行样本划分, 窗口长度 $N=192$, 步长为 96。为确保标签的准确性, 本文采用双算法交叉验证策略进行辅助验证标注。将处理的信号经过文献[4, 29]交叉验证, 分别应用多尺度稳定性分析方法与方差稳定性度量方法进行磨粒信号识别, 当两种方法的判定结果一致, 视为高置信度磨粒信号, 赋予相应标签。由于高梯度静磁场传感器在非铁磁金属检测上存在原理性缺陷, 为保证验证的全面性, 将通过其采集的铁磁磨粒信号进行等比分割, 并对其中一半进行反向操作, 获取非铁磁性磨粒信号的数据集。干扰样本在不包含磨粒信号特征的区间中随机选取。

数据集构成如表 2 所示, 其中仿真样本依据文献[28]中提出的数学模型生成, 关键参数根据实验信号的特征区间并结合不同 SNR 随机设定。

表 2 数据集构造

Table 2 The construction of dataset

数据集	类型	数量	标签
三线圈 (TC)	铁磁性	120	TFD
	非铁磁性	120	TNFD
高梯度 (HG)	铁磁性	120	HFD
	非铁磁性	120	HNFD
仿真	混合组成	4 000×6	SE
干扰		6 000	IE

3.2 模型性能评估

为验证训练模型的识别性能, 采用 3 个基于分类混淆矩阵的评价指标, 即干扰排除率 (interference elimination rate, IER)、磨粒识别率 (debris identification rate, DIR)、磨粒识别准确率 (debris identification accuracy, IACC), 定义如式 (23) 所示。

$$\begin{cases} IER = 1 - \rho_i / (\rho_i + \rho_f) \\ DIR = (\rho_{d_1} + \rho_{d_2}) / (\rho_{d_1} + \rho_{d_2} + \rho_m + \rho_i) \\ IACC = (\rho_{d_1} + \rho_{d_2}) / (\rho_{d_1} + \rho_{d_2} + \rho_m) \end{cases} \quad (23)$$

其中, ρ_{d_1} , ρ_{d_2} 表示模型正确识别的两类磨粒信号数量; ρ_i 表示干扰信号被误判为磨粒信号的数量; ρ_f 表示磨粒信号被误判为干扰信号的数量; ρ_m 表示不同类别磨粒之间的互相误判情况。

选取多种典型的故障诊断深度学习模型作为对比, 包括 1D-ViT^[27]、WDCNN^[30]、ResNet50^[31]、ResNet-CBAM^[24]与 MA1DCNN^[16]。所有模型均训练 50 个周期, 训练数据由等量的磨粒样本与随机选取的干扰样本组成。每组实验重复 20 次, 取结果的平均值作为评估指标。

由于仿真信号与传感器采集信号存在一定差异, 仅依赖单一的仿真信号进行训练, 易导致模型性能下降, 本文在模型训练中引入迁移学习策略, 在仿真信号样本上预训练并结合有限的实验磨粒信号样本微调模型参数, 提升模型的泛化能力。如图 5 所示, 展示了各模型在 0 dB 仿真集下结合 1/3HG 样本训练后的结果。结果表明, 现有模型在保留磨粒信号与排除干扰段之间难以取得平衡, 同时颗粒材料的分类能力较差, 相比之下, 所提模型 PCatten 的 IER 为 98.21%, DIR 为 95.39%。此外, 在少样本学习中, PCatten 对不同类型磨粒的分类能力也显著优于其他模型。

如图 6 所示, 展示了使用全部 HG 样本训练后, 各模型在不同 SNR 仿真集上的性能表现。

如表 3 所示, 展示了模型抗干扰能力验证结果, PCatten 的平均 IER 最佳且有最小的标准差。在 0 dB 仿

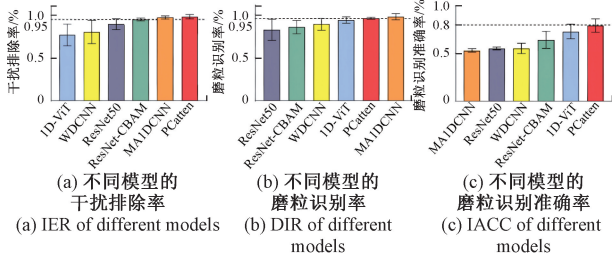


图 5 各模型在仿真数据上的性能对比结果
Fig. 5 Results of different models on simulation data




图 6 不同模型抗噪能力的验证结果
Fig. 6 Anti-noise capability verification of each model

表 3 不同模型在完整训练样本下的 IER 对比
Table 3 IER of different models with full training samples (%)

模型	IER±STD
WDCNN	95.51±0.14
ResNet50	95.53±0.15
1D-ViT	96.09±0.17
MA1DCNN	97.78±0.09
ResNet-CBAM	98.96±0.11
PCatten	99.21±0.08

真集上, WDCNN、1D-ViT、ResNet50 和 ResNet-CBAM 的 DIR 均低于 86%, 并在 SNR 降至 -5 dB 时急剧下降至 34.5% 以下。虽然 MA1DCNN 在 SNR = 0 时表现最佳, 但当 SNR 低于 -2 dB 时, 性能急剧下降, 在 -5 dB 时, DIR 仅为 32.06%。相比之下, PCatten 在 0 dB 时的 DIR 为 98.13%, 在 -5 dB 时缓慢下降至 71.7%, 表明在低 SNR 环境下 PCatten 具有更强的抗噪能力。同时, 所提模型平均 IACC 最高且性能最稳定。为评估模型的泛化能力, 本文采用跨数据集的交叉验证策略, 分别在 TC 与 HG 数据集之间进行训练与测试。结果如图 7 所示, PCatten 在两类实验数据集上均实现了稳定且优异的识别性能。

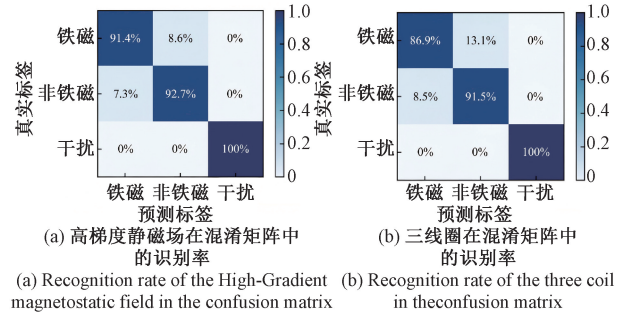


图 7 交叉验证混淆矩阵

Fig. 7 The cross-validation confusion matrix

如表 4 所示, 仅使用 0 dB 仿真样本训练的 PCatten 在两类实验数据集中均获得优异表现, 且随着训练样本数量的增加, IACC 进一步提升。

表 4 PCatten 在仿真样本训练下的性能结果
Table 4 Performance of the PCatten trained by simulation samples (%)

数据集	DIR	IER	IACC
TC	95.51±0.14	100	98.87±0.12
HG	100	100	97.46±0.11

采用 T-SNE 高维特征可视化方法, 对基于 TC 数据集训练的不同模型在测试样本上的特征提取结果进行可视化分析, 如图 8 所示。WDCNN、ResNet50、1D-ViT 和 ResNet-CBAM 提取的特征在类别边界上划分不清晰, 区分度不足。MA1DCNN 区分磨粒样本的误判概率较低, 但仍有部分干扰信号与磨粒特征混杂。PCatten 表现出优异的判别能力, 不同类别的样本在特征空间中呈现出清晰的分界, 聚类效果最佳。

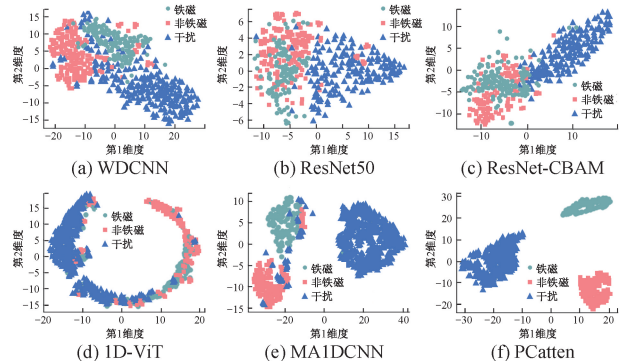


图 8 各模型在 TC 测试集上的特征可视化结果
Fig. 8 The visualization of the extracted features by different models on the TC testing set

如图 9 所示, 展示了 PCatten 分别在结合注意力模块、结合 CAM^[16] 和 CBAM^[30] 所提取特征的可视化结果。

与 FAM 相比,结合的注意力机制未能保证有效的类别区分,在未引入空间注意力时更出现大量误判。这一结果验证了功率感知在特征提取中的重要性,并证明 FAM 在提升磨粒特征识别与分类性能方面的优势。




图9 PCatten 在不同注意力模块下的特征可视化

Fig. 9 The visualization of the extraction features by PCatten with different attention modules respectively

3.3 关键参数讨论

为探究多尺度特征构造对 PCatten 模型识别性能的影响,此次实验均用离散小波分解代替多尺度低通滤波,通过改变小波分解层数,分析其对模型性能的影响,选取最优小波分解层数。实验中,采用 TC 数据集进行训练,并以 0 dB 仿真集作为验证,所得结果如图 10(a) 所示。

当分解层数设置为 2 和 3 时,小波分解尺度过少,模型对低频特征的捕获不充分,分解层数由 2 增加到 4, IER、DIR 和 IACC 均显著提升,在分解层数为 4 时取得最佳性能。尽管当分解层数增加到 5 和 6 模型仍能取得相近的良好效果,但由于参数数量增加,导致模型计算量增大,计算效率降低。

不同小波分解层数的模型 loss 曲线如图 10(b) 所示,各组曲线均随着训练迭代单调下降,在约前 200 次迭代阶段损失迅速衰减,随后进入缓慢收敛区间,并在 400 次迭代之后趋于稳定。随着小波分解层数增多,loss 曲线明显下移且收敛更迅速,当层数大于 4 时,loss 曲线相较层数为 4 已无显著改善,且 loss 值趋于稳定。综合分析,本文实验将小波分解层数设置为 4。

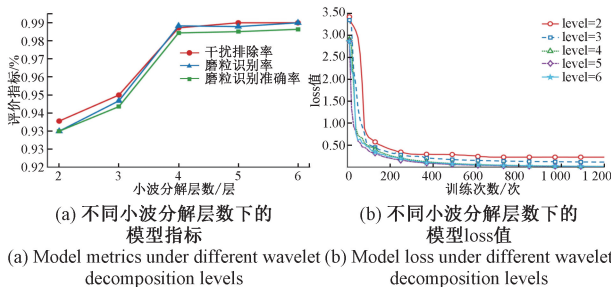


图10 不同小波分解层数下模型的性能对比

Fig. 10 Comparison of model performance under different wavelet decomposition levels

3.4 可解释性分析

在本节中,通过特征可视化和相似性计算对 PCatten

模型的可解释性进行了探究。从 HG 数据集中选取两种不同类型的磨粒样本,并从干扰数据集中选取一种典型干扰信号样本,对重构后的 MFF 进行可视化,如图 11 所示。

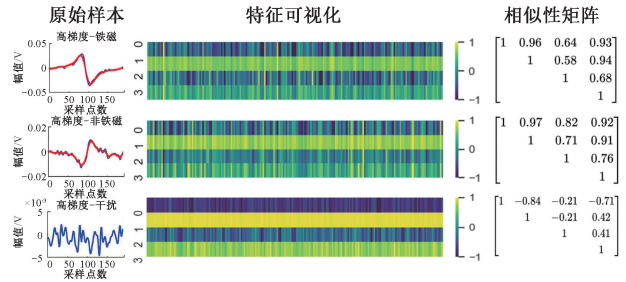


图11 不同样本重构 MFF 的可视化与相似性度量

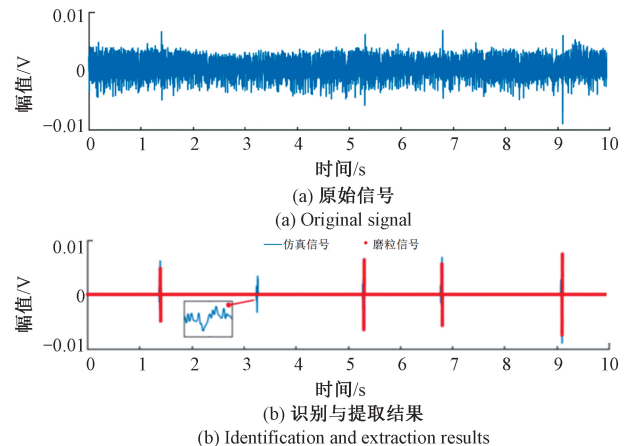
Fig. 11 Visualization of the reconstructed MFF of different samples and the similarity calculation

FAM 通过全局与局部注意力加权实现特征重新校准,增强了重构 MFF 之间突出值的差异,特别是对于干扰信号,相较于磨粒特征表现出更大的变化幅度。特征可视化结果显示,两种磨粒感应电压信号的重构 MFF 在局部特征上具有更明显的相似性。相似矩阵进一步量化了不同样本间的差异,并由于重构与加权操作的极性差异,负相关性被保留。然而,磨粒特征的重构 MFF 之间的平均相关性显著高于干扰信号,这与本文提出的理论框架一致,验证了方法的可解释性。

综上所述,PCatten 的自注意力模块通过重构的 MFF 有效地捕获磨粒感应电压信号的隐含特征,增强了模型区分磨粒感应电压信号与干扰信号的能力。

3.5 磨粒检测验证

如图 12 所示,展示了一个长度为 50 000,包含 4 个磨粒的仿真信号的识别结果,此例中所使用的 PCatten 模型是以 TC 数据集为训练样本。可以看出,模型能够准确提取所有磨粒感应电压信号,有效保留局部特征。结果中存在一个假磨粒辨识结果,表明在低 SNR 条件下,部分干扰信号的时域形态与磨粒相似,PCatten 可能导致误识别,但总体误判率较低。



(b) Identification and extraction results




图 12 PCatten 对仿真信号的识别结果

Fig. 12 The identification results of simulation signal by PCatten

为进一步验证所提方法在实际检测中的优势,采用基于峭度度量的采用基于峭度度量的辛几何模态分解(spectral-grouping-based mode decomposition, SGMD)^[7]与平移不变小波变换(translation invariant wavelet transform, TIWT)^[6]滤波算法进行对比。其中, TIWT 的分解层数设定为 4, 从 SGMD 分解的 17 个子分量中选取第 1 和第 14 个子分量用于磨粒信号的重构。上述方法在一段包含 8 个磨粒信号的 HG 实验信号上进行, 实验过程中所有预设参数与前文保持一致。

PCatten 的磨粒感应电压信号辨识结果如图 13 所示, 如图 14(a)、(b)所示, 分别展示了 SGMD 与 TIWT 的检测结果。可以看出, SGMD 与 TIWT 的检测结果均包含了 PCatten 识别的全部磨粒信号。然而, 在残余信号中仍保留部分疑似磨粒感应电压信号, 导致计数结果与实际投放颗粒数不符。通过与两种传统方法比较, 基于 PCatten 的磨粒识别方法具有更优的抗干扰能力。




图 13 PCatten 对实验信号的识别结果

Fig. 13 The identification results of experimental signal by PCatten



(a) SGMD 识别结果
(a) The identification results of the SGMD(b) TIWT 识别结果
(b) The identification results of the TIWT

图 14 SGMD 与 TIWT 识别结果

Fig. 14 The identification results of the SGMD and TIWT

4 结 论

为实现磨粒特征的准确识别, 避免复杂的阈值选择以及局部特征的失真, 提出了一种融合几何形态稳定性的可解释神经网络。方法通过捕捉重构 MFF 之间的依赖关系, 实现对磨粒信号与非磨粒信号的有效区分。本文在已搭建的平台上开展实验, 并基于两种典型传感器的数据集验证所提模型的有效性。数据仿真与实验结果表明, PCatten 相比现有模型具有更强的抗噪能力和更优的识别精度, 同时兼具泛化性与可解释性。与传统算法相比, 所提 PCatten 的智能检测方法在低 SNR 环境下表现出更强的检测能力和特征保护能力, 为磨粒检测的量化分析与工程应用提供了有力的技术支撑。

参考文献

- [1] 萧红, 周威, 罗久飞, 等. 一种高梯度静磁场感应式全流量磨粒监测传感器[J]. 仪器仪表学报, 2020, 41(6): 10-18.
XIAO H, ZHOU W, LUO J F, et al. An inductive sensor based on the high-gradient static magnetic field for full flow debris monitoring [J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 10-18.
- [2] 孙衍山, 杨昊, 佟海滨, 等. 航空发动机滑油磨粒在线监测[J]. 仪器仪表学报, 2017, 38(7): 1561-1569.
SUN Y SH, YANG H, TONG H B, et al. Review of on-line detection for wear particles in lubricating oil of aviation engine [J]. Chinese Journal of Scientific Instrument, 2017, 38(7): 1561-1569.
- [3] LUO J F, LI J, WANG X Y, et al. An inductive sensor based multi-least-mean-square adaptive weighting filtering for debris feature extraction [J]. IEEE Transactions on Industrial Electronics, 2023, 70(3): 3115-3125.
- [4] 罗久飞, 郑睿, 王鑫宇, 等. 油液磨粒感应电压特征辨识研究[J]. 仪器仪表学报, 2022, 43(8): 173-181.
LUO J F, ZHENG R, WANG X Y, et al. Study on feature identification of oil debris induced voltages [J]. Chinese Journal of Scientific Instrument, 2022, 43(8): 173-181.
- [5] FAN X, LIANG M, YEAP T. A joint time-invariant wavelet transform and kurtosis approach to the improvement of in-line oil debris sensor capability [J]. Smart Materials and Structures, 2009, 18(8): 085010.
- [6] YU B, CAO N, ZHANG T H. A novel signature extracting approach for inductive oil debris sensors based on symplectic geometry mode decomposition [J].

- Measurement, 2021, 185: 110056.
- [7] LIU H K, LI T Y, HONG W, et al. Using multi-window correlation to improve sensitivity and adaptability for oil debris detections [J]. Measurement, 2021, 176: 109236.
- [8] HONG W, WANG SH P, LIU H K, et al. A hybrid method based on band pass filter and correlation algorithm to improve debris sensor capacity [J]. Mechanical Systems and Signal Processing, 2017, 82: 1-12.
- [9] ZHAO R, YAN R Q, CHEN ZH H, et al. Deep learning and its applications to machine health monitoring [J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.
- [10] 刘艳丽,王浩,张帆. 基于轻量卷积和模型优化的电弧故障检测方法[J]. 仪器仪表学报, 2024, 45(10): 38-49.
- LIU Y L, WANG H, ZHANG F, et al. Arc fault detection method based on lightweight convolution and model optimization [J]. Chinese Journal of Scientific Instrument, 2024, 45(10): 38-49.
- [11] DURAN B, EMORY D, EFTEKHAR AZAM Y, et al. A novel CNN architecture for robust structural damage identification via strain measurements and its validation via full-scale experiments [J]. Measurement, 2025, 239: 115393.
- [12] 雷春丽,夏奔锋,薛林林,等. 小样本下自校正卷积神经网络的滚动轴承故障识别方法[J]. 仪器仪表学报, 2022, 43(9): 122-130.
- LEI CH L, XIA B F, XUE L L, et al. Fault identification for rolling bearing by self-calibrated convolutional neural network under small samples conditions [J]. Chinese Journal of Scientific Instrument, 2022, 43(9): 122-130.
- [13] LIAO Y L, WANG Y H, ZENG X P, et al. Multiscale 1-DCNN for damage localization and quantification using guided waves with novel data fusion technique and new self-attention module [J]. IEEE Transactions on Industrial Informatics, 2024, 20(1): 492-502.
- [14] WANG Q, XU F Y. A novel rolling bearing fault diagnosis method based on adaptive denoising convolutional neural network under noise background [J]. Measurement, 2023, 218: 113209.
- [15] LI F, WANG L P, WANG D CH, et al. An adaptive multiscale fully convolutional network for bearing fault diagnosis under noisy environments [J]. Measurement, 2023, 216: 112993.
- [16] WANG H, LIU ZH L, PENG D D, et al. Understanding and learning discriminant features based on multiattention 1DCNN for wheelset bearing fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(9): 5735-5745.
- [17] 徐大伟,梁晨硕,胡东阳,等. 基于物理信息嵌入的绳驱机械臂绳索故障诊断与隔离方法[J]. 仪器仪表学报, 2025, 46(9): 311-322.
- XU D W, LIANG CH SH, HU D Y, et al. Cable fault diagnosis and isolation method for cable-driven manipulators based on physics-informed embedding [J]. Chinese Journal of Scientific Instrument, 2025, 46(9): 311-322.
- [18] JIA N, HUANG W G, DING CH C, et al. Physics-informed unsupervised domain adaptation framework for cross-machine bearing fault diagnosis [J]. Advanced Engineering Informatics, 2024, 62: 102774.
- [19] 乔卉卉,赵二贤,郝如江,等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报, 2024, 45(9): 120-130.
- QIAO H H, ZHAO ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 120-130.
- [20] 王俊,杨轶青,刘金朝,等. 小波核编码的脉冲卷积神经网络在可解释性智能诊断中的应用研究[J]. 机械工程学报, 2024, 60(12): 41-50.
- WANG J, YANG Y Q, LIU J ZH, et al. Interpretable intelligent diagnosis based on wavelet kernel encoded spiking convolutional neural networks [J]. Journal of Mechanical Engineering, 2024, 60(12): 41-50.
- [21] JIANG G Q, WANG J, WANG L J, et al. An interpretable convolutional neural network with multi-wavelet kernel fusion for intelligent fault diagnosis [J]. Journal of Manufacturing Systems, 2023, 70: 18-30.
- [22] WANG H, LIU Z L, PENG D D, et al. Interpretable convolutional neural network with multilayer wavelet for noise-robust machinery fault diagnosis [J]. Mechanical Systems and Signal Processing, 2023, 195: 110314.
- [23] 曾周末,许恩蕾,黄新敬,等. 高灵敏低电压电磁感应式滑油磨屑传感器[J]. 仪器仪表学报, 2022, 43(2): 1-9.
- ZENG ZH M, XU EN L, HUANG X J, et al. High-sensitivity, low-voltage lubricating oil wear debris sensor based on electromagnetic induction [J]. Chinese Journal

of Scientific Instrument, 2022,43(2):1-9.

- [24] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision. Cham: Springer, 2018: 3-19.
- [25] KIM M S, YUN J P, PARK P G. An explainable convolutional neural network for fault diagnosis in linear motion guide[J]. IEEE Transactions on Industrial Informatics, 2021, 17(6): 4036-4045.
- [26] WU H P, XIAO B, CODELLA N, et al. Cvt: Introducing convolutions to vision transformers[C]. 2021 IEEE/CVF International Conference on Computer Vision, 2021: 22-31.
- [27] XU P H, ZHANG L J. A fault diagnosis method for rolling bearing based on 1D-ViT model [J]. IEEE Access, 2023, 11: 39664-39674.
- [28] FENG S, TAN J, WEN Y, et al. Sensing model for detecting ferromagnetic debris based on a high-gradient magnetostatic field [J]. IEEE/ASME Transactions on Mechatronics, 2022, 27(5): 2440-2449.
- [29] 李海青,刘伟,冯松,等. 感应式磨粒检测传感器信号特征提取方法研究[J]. 电子测量与仪器学报,2022, 36(12):1-9.
- LI H Q, LIU W, FENG S, et al. Research on signal feature extraction for inductive debris detection sensor[J]. Journal of Electronic Measurement and Instrumentation, 2022,36(12):1-9.
- [30] ZHANG W, PENG G L, LI CH H, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals [J]. Sensors, 2017, 17(2): 425.
- [31] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.

作者简介



罗久飞,

E-mail:luojf@cqupt.edu.cn

Luo Jiufei received his B. Sc. and M. Sc. degrees both from Chongqing University of Technology in 2009 and 2012, and Ph. D. degree from Chongqing University in 2015. He is currently a professor and Ph. D. candidate supervisor at School Integrated Circuits, Chongqing University of Posts and Telecommunications. His main research interests include intelligent sensors, applications of digital signal processing and analysis and robotics.



尹爱军(通信作者),分别于2001年、2003年和2006年在重庆大学获得学士学位以及硕士、博士学位,目前任职于重庆大学机械与运载学院教授,博士生导师,其当前研究方向包括:机器视觉与图像处理、机器学习、智能检测与仪器、无损检测与评价、现代信号分析与处理以及故障检测与诊断。

E-mail:aijun.yin@cqu.edu.cn

Yin Aijun (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Chongqing University in 2001, 2003 and 2006, respectively. He is currently a professor and Ph. D. advisor at the College of Mechanical and Vehicle Engineering, Chongqing University. His main research interests include machine vision and image processing, machine learning, intelligent testing and instruments, nondestructive testing and evaluation, modern signal analysis and processing, and fault detection and diagnosis.