

DOI: 10.19650/j.cnki.cjsi.J2614875

# 基于持续学习大模型的增量故障诊断维护决策\*

李 川<sup>1,2</sup>, 郭改芳<sup>1,2</sup>, 郭 圳<sup>1</sup>, 蒲自强<sup>1</sup>

(1. 重庆工商大学装备系统服役健康保障国际联合研究中心 重庆 400067; 2. 重庆工商大学管理科学与工程学院 重庆 400067)

**摘 要:**长期运行的工业设备会持续涌现新故障模式,这对增量诊断维护决策的持续学习能力提出要求。但是,工程实际中普遍存在的少样本与类别不平衡问题,为高效持续学习带来挑战。为此,提出一种持续学习大模型,解决复杂条件下的增量故障诊断与维护决策问题。设计嵌入多尺度高效通道与空间注意力的宽核深度卷积网络,利用并行卷积分支同步捕捉振动信号瞬态冲击与周期调制特征,通过自适应筛选关键故障频段来提取高判别性故障表征。提出随机记忆回放结合可扩展线性分类器的增量学习策略,随机留存少量历史类别范例参与后续训练。在增量学习阶段保持历史类别权重不变,仅扩展分类层参数以缓解长周期持续学习的灾难性遗忘问题。设计投影适配层将数值故障特征映射至大模型词嵌入空间,搭建振动信号与文本语义的跨模态对齐框架,借助低秩适配策略微调注意力层低秩矩阵完成领域适配,驱动大模型输出类增量诊断维护决策结果。所提出的持续学习大模型在设备运维公共数据集和自有齿轮箱试验台上进行实验,并开展多组对比分析与消融测试。结果表明,该模型在少样本和类别不平衡场景下均表现优异,其增量故障诊断维护决策的学习遗忘率显著低于对比方法。

**关键词:**持续学习;大模型;故障诊断;维护决策;智能运维

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

## Incremental fault diagnosis and maintenance decision-making using a continual learning-based large language model

Li Chuan<sup>1,2</sup>, Guo Gaifang<sup>1,2</sup>, Guo Zhen<sup>1</sup>, Pu Ziqiang<sup>1</sup>

(1. Research Center for System Health Maintenance, Chongqing Technology and Business University, Chongqing 400067, China;  
2. School of Management Science and Engineering, Chongqing Technology and Business University, Chongqing 400067, China)

**Abstract:** New fault modes keep emerging during the long-term operation of industrial equipment, demanding continual learning for incremental diagnosis and maintenance decision-making. However, few-shot samples and class imbalance in practical engineering pose challenges to effective continual learning. To address these issues, a continual learning-based large language model (CL-LLM) is proposed for incremental fault diagnosis and maintenance decision-making under complex conditions. A wide-kernel deep convolutional network embedded with multi-scale efficient channel and spatial attention is designed. It adopts parallel convolution branches to synchronously capture the transient impact and periodic modulation features of vibration signals. Discriminative representations are extracted by adaptively screening key fault frequency bands. An incremental learning strategy combining random memory replay and a scalable linear classifier is proposed to retain a small number of historical category samples for subsequent training. During the incremental learning phase, the weights of historical categories are fixed. Only classification layer parameters are expanded to mitigate the catastrophic forgetting of CL-LLM in long-term continual learning. A projection adaptation layer is designed to map numerical fault features to the embedding space of the large language model, constructing a cross-modal alignment framework for vibration signals and text semantics. A low-rank adaptation strategy is adopted to fine-tune the low-rank matrices of attention layers for domain adaptation, enabling CL-LLM to output class-incremental diagnosis and maintenance decision results. Experiments are implemented on a public equipment operation and maintenance dataset and the self-built gearbox test rig, followed by comparative analysis and ablation studies.

收稿日期: 2026-01-20 Received Date: 2026-01-20

\* 基金项目: 国家重点研发计划(2023YFB3406104)、国家自然科学基金(52575103)、重庆市自然科学基金(CSTB2025NSCQ-LZX0128)项目资助

The results show that the proposed CL-LLM performs excellently in few-shot and class-imbalanced scenarios. Its learning forgetting rate for incremental fault diagnosis and maintenance decision-making is significantly lower than that of comparative methods.

**Keywords:** incremental learning; large language model; fault diagnosis; maintenance decision-making; intelligent operation and maintenance

## 0 引言

在人工智能与制造业融合发展进程中,设备智能运维已成为保障工业系统安全稳定运行、优化全生命周期管理成本和提升核心生产效能的关键<sup>[1]</sup>。故障诊断与维护决策作为核心运维环节,为设备主动维护和精准管控提供了有力支撑<sup>[2]</sup>。受限于工业现场传感数据采集成本和设备故障样本的稀缺性,实际的设备运维普遍存在小样本<sup>[3]</sup>、数据分布不平衡<sup>[4]</sup>、故障类别增量演化<sup>[5]</sup>等现实问题。例如,工业设备的早期故障样本往往难以充分采集,正常工况数据与故障数据的数量级差异显著。随着设备服役年限增长与工况变化,还会不断涌现未预定义的新故障类别,这为故障模式的精准诊断与维护策略的动态制定带来严峻挑战。

在实际工业场景中,数据驱动模型在少样本条件下难以对设备故障诊断进行泛化。为解决这一问题, Ma 等<sup>[6]</sup>提出了结合动力学机制建模和增强元迁移学习的混合框架,诊断轴向柱塞泵故障。Ma 等<sup>[7]</sup>结合多阶图嵌入堆叠去噪自编码器与协作中心域适应模型,通过少量标记样本实现滚动轴承故障的稳定诊断。为缓解故障数据集中正常工况样本与故障样本、不同类型故障样本间的数量级失衡问题, Li 等<sup>[8]</sup>引入先验知识与对比损失函数,提出一种在训练样本极端不平衡条件下仍能有效诊断旋转机械故障的方法。Shi 等<sup>[9]</sup>提出一种基于图嵌入的深度广度学习系统,通过融入数据类别与结构信息、考虑类别权重与类内紧密度,解决了故障诊断中监测数据分布不平衡的问题。王报详等<sup>[10]</sup>提出了改进循环一致生成对抗网络,用于生成高质量的故障数据样本,从而提高数据不平衡下的机械故障智能诊断精度。王玉静等<sup>[11]</sup>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。在实际工业场景中,设备故障类别会随服役工况变化和部件老化而持续涌现新类故障。传统诊断方法因灾难性遗忘丧失对历史故障的识别能力,难以满足长期运维对模型持续学习与适配的需求。石明宽等<sup>[12]</sup>提出一种持续迁移学习故障诊断方法,通过处理变工况下具有非独立同分布特性的工业流数据,在无需重放旧数据的情况下持续学习新故障类别。Zheng 等<sup>[13]</sup>提出基于 Blaschke 逼近定理的新型分类器 Blaschke 学习机,通过动态 Blaschke 系统分解输入并建模输入-输出映射关系,能够高效支持 3 类增量学习,在非平稳条件下实

现高精度、低资源消耗的持续故障诊断。

近年来,以 Transformer 架构为代表的大语言模型凭借强大的特征提取与泛化能力,逐渐引入设备智能运维领域,展现出良好的应用潜力<sup>[14]</sup>。预训练大模型可借助海量通用数据知识,缓解小样本场景下的故障诊断模型过拟合问题。通过结合大模型与迁移学习,可以实现跨工况和跨设备的故障特征迁移诊断<sup>[15]</sup>。黄金凤等<sup>[16]</sup>提出一种面向机械设备运维的思维链范式文本基多模态智能体。Xiao 等<sup>[17]</sup>提出一种知识引导语义表示与大型语言模型的通用故障诊断框架,将振动信号转化为可解释的文本序列,利用低秩自适应的知识引导提示调优,使大模型能有效整合专家先验知识,在少样本迁移和跨工况适应任务中实现了高精度轴承故障诊断。尽管大模型的内在架构使其对小样本、数据不平衡问题具备一定的天然泛化能力,但设备智能运维领域仍然缺乏具备持续学习能力的大模型,难以应对工业场景中故障类别持续增量、设备状态动态演化的需求,制约了智能运维技术在复杂工业环境中的应用。

为应对上述挑战,本文提出一种基于持续学习的大语言模型 (continual learning-based large language model, CL-LLM), 解决设备生命周期中普遍存在的类增量故障诊断和维护决策问题。

本文设计了多尺度高效通道与空间注意力 (multi-scale efficient channel and spatial attention, MECS) 模块,并将其嵌入宽核深度卷积神经网络 (wide-kernel deep convolutional network, WDCNN), 构建面向振动信号持续学习任务的专用特征提取网络,能够充分挖掘增量任务下不同故障类别深层特征。提出一种基于随机记忆回放的持续学习策略及其对应的可扩展线性分类器,将数值信号特征与大模型 (large language model, LLM) 语义令牌映射的特征对齐。即使在类增量小样本和不平衡挑战下也通过大模型持续学习,生成高质量故障诊断及其维护决策结果。

## 1 持续学习大模型构建方法

### 1.1 问题背景与总体框架

类增量故障诊断是设备持续运行过程中面临的常见场景<sup>[18]</sup>。为有效解决该问题,诊断模型需要在不遗忘已学习故障类别知识的前提下,持续学习新增故障类别并实现故障诊断,该类增量过程如图 1 所示。




图1 类增量持续学习过程示意图

Fig. 1 Schematic of the class-incremental continual learning

给定一个设备状态监测振动信号数据集,其故障类别集合随时间划分为多个批次  $C_1, C_2, \dots, C_t, \dots, C_T$ , 其中第  $t$  批次的新增故障类别表示为:

$$C_t = \{y_{t,1}, y_{t,2}, \dots, y_{t,N_t}\} \quad (1)$$

式中:  $y$  为类别标签;  $N_t$  为第  $t$  批次的类别数,且满足批次间类别互不相交 ( $C_i \cap C_j = \emptyset, i \neq j$ )。

这些批次对应的数据为  $\{D_1, D_2, \dots, D_t, \dots, D_T\}$ , 第  $t$  批次的样本集合表示为:

$$D_t = \{(x_{t,i}, y_{t,i}) \mid i = 1, 2, \dots, M_t\} \quad (2)$$

式中:  $x_{t,i} \in \mathbf{R}^d$  为故障特征向量;  $y_{t,i} \in C_t$  为类别标签;  $M_t$  为第  $t$  批次的样本数量。

为解决以上持续过程的增量故障诊断维护决策问题,提出持续学习大模型 CL-LLM 如图 2 所示。通过采集设备振动信号,该大模型在总体框架上实现特征提取、桥接、推理与生成等故障诊断维护决策的 3 个基本功能。其中,特征提取功能在感知层实现,具体结构由基于 MECS 的 WDCNN 实现;桥接功能在对齐和存储层实现,具体结构由记忆库、可扩展分类器、对齐和低秩 (low-rank adaptation, LoRA) 适配器通过持续学习策略实现;推理与生成在认知层实现,具体结构由通用大模型经过模态对齐和调整适配实现。




图2 持续学习大模型的工作原理示意图

Fig. 2 Schematic of the present CL-LLM

## 1.2 基于 MECS 机制的多尺度特征提取

传统的卷积神经网络受限于固定感受野,难以同时捕捉瞬态冲击与周期性特征。为此,构建了一个嵌入 MECS 的特征提取网络  $F_\theta$ 。由图 2 中感知层可知,特征提取主要由 WDCNN 与 MECS 模块交替堆叠而成。

设原始一维振动信号为  $\mathbf{x} = [x_1, x_2, \dots, x_L] \in \mathbf{R}^{1 \times L}$ , 其中  $L$  为信号长度。感知层进行特征提取的目标是

学习一个非线性映射  $F_\theta: \mathbf{R}^L \rightarrow \mathbf{R}^D$ , 将高维原始信号映射到低维且具有判别性的特征空间  $\mathbf{z} \in \mathbf{R}^D$ , 即:

$$\mathbf{z} = F_\theta(\mathbf{x}) \quad (3)$$

式中:  $\mathbf{z}$  为后续分类器或大语言模型适配器输入。

考虑到原始振动信号中可能含有大量宽频背景噪声,第 1 层卷积层设计为大卷积核,充当带通滤波器以提取不同频段的特征并抑制高频噪声。对于第  $l$  层卷积

核,输入特征图为  $\mathbf{H}^{l-1}$ ,则第  $k$  个卷积核输出的特征图可表示为:

$$\mathbf{U}_k^l = \mathbf{W}_k^l * \mathbf{H}^{l-1} + \mathbf{b}_k^l \quad (4)$$

式中:  $*$  表示一维卷积运算;  $\mathbf{W}_k^l$  和  $\mathbf{b}_k^l$  分别表示第  $l$  层的第  $k$  个卷积核权重和偏置。

为了缓解内部协变量偏移并加速训练收敛,在每个卷积操作后引入了批归一化。对于当前批次中的特征响应值  $\mathbf{u}$ ,批归一化定义如下:

$$\hat{\mathbf{u}} = \frac{\mathbf{u} - \mathbf{u}_B}{\sqrt{\sigma_B^2 + \varepsilon}}, \mathbf{Y}_k^l = \gamma \hat{\mathbf{u}} + \beta \quad (5)$$

式中:  $\mu_B$  和  $\sigma_B^2$  分别是当前数据的均值和方差;  $\gamma$  和  $\beta$  是可学习的缩放与平移参数。

随后采用修正线性单元 (rectified linear unit, ReLU) 激活函数<sup>[19]</sup>增强非线性表达能力,并使用最大池化层来降低特征维度并保持特征的平移不变性,在第  $l$  层得到最终输出为:

$$\mathbf{H}^l = \max\text{Pool}(\text{ReLU}(\mathbf{Y}^l)) \quad (6)$$

式中:  $\text{ReLU}(\cdot)$  为 ReLU 激活函数;  $\text{Pool}(\cdot)$  为池化操作。

为了增强特征的辨别力,在卷积块后引入了 MECS 模块。该模块由多尺度时序感知与自适应通道门控两个子模块串行组成。令 MECS 模块的输入特征为  $\mathbf{h}_{in} \in \mathbf{R}^{C \times L}$ ,为了同时捕捉瞬态冲击与周期性调制,设计了双路并行卷积分支,小卷积核和大卷积核分别为  $\mathbf{u}_s$  和  $\mathbf{u}_l$ ,表达为:

$$\mathbf{u}_s = \text{Conv1D}(\mathbf{h}_{in}), \mathbf{u}_l = \text{Conv1D}(\mathbf{h}_{in}) \quad (7)$$

式中:  $\text{Conv1D}(\cdot)$  表示一维卷积操作。经过卷积得到的特征经过通道维度拼接与  $1 \times 1$  卷积层进行特征融合,得到融合特征:

$$\mathbf{u}_f = \text{Conv1D}_{1 \times 1}([\mathbf{u}_s; \mathbf{u}_l]) \quad (8)$$

式中:  $[\cdot; \cdot]$  表示通道拼接操作。

为了动态筛选关键特征通道,在融合特征后引入了基于压缩和激励的门控机制。首先,通过全局平均池化将特征压缩为通道描述符  $\mathbf{s} \in \mathbf{R}^C$ ,其第  $c$  个通道的全局统计量为:

$$\mathbf{s}_c = \frac{1}{L'} \sum_{i=1}^{L'} \mathbf{u}_f(c, i) \quad (9)$$

式中:  $L'$  表示当前层特征图的时间维度长度。

利用一个瓶颈结构的 MLP<sup>[20]</sup>学习通道间的非线性依赖,生成门控权重  $\mathbf{w} \in \mathbf{R}^C$ :

$$\mathbf{w} = \text{Sig}(\mathbf{W}_{up} \cdot \text{ReLU}(\mathbf{W}_{down} \cdot \mathbf{s})) \quad (10)$$

式中:  $\text{Sig}(\cdot)$  为 Sigmoid 函数<sup>[20]</sup>将权重约束在 0~1 之间;  $\mathbf{W}_{down}$  和  $\mathbf{W}_{up}$  为可学习参数。最终的输出通过逐通道加权与残差连接获得:

$$\mathbf{z} = \mathbf{h}_{out} = \mathbf{h}_{in} + (\mathbf{u}_f \otimes \mathbf{w}) \quad (11)$$

式中:  $\otimes$  表示逐通道相乘。通过以上操作,感知层将设备采集的原始振动信号提取得到特征向量  $\mathbf{z}$ ,用于后续的分类

增量持续学习和故障诊断维护决策的大模型推理与生成。

### 1.3 基于随机记忆回放的增量学习策略

在类增量场景下,持续学习在引入新类别时容易发生灾难性遗忘,导致对已学习类别的判别能力显著下降。为此,采用基于范例随机回放的类增量策略来解决持续学习的挑战。

与基于度量学习的原型分类策略不同,研究在分类阶段采用标准线性分类层,通过全连接映射实现特征到类别空间的投影。设特征提取网络输出的特征向量为  $\mathbf{f}_i \in \mathbf{R}^d$ ,线性分类器的输出  $\mathbf{z}_i$  定义为:

$$\mathbf{z}_i = \mathbf{W} \cdot \mathbf{f}_i + \mathbf{b} \quad (12)$$

式中:  $\mathbf{W} \in \mathbf{R}^{C \times d}$  和  $\mathbf{b} \in \mathbf{R}^C$  分别表示分类层的权重矩阵与偏置向量;  $C$  为当前阶段已学习的类别数。在增量阶段,当引入新类别时,仅对分类层进行结构性扩展,为新类别初始化对应的权重参数,而保持已有类别权重不变。避免了复杂的原型维护机制,使模型能够以更直接的方式适应类别空间的动态变化。

为缓解灾难性遗忘问题,引入了基于范例的记忆回放机制。在每个增量阶段,仅为每个已学习类别保留固定数量的代表性样本,并在后续训练阶段进行回放。与 Herding 等基于特征中心的选择策略不同<sup>[21]</sup>,本文采用随机采样方式构建记忆库。对每一类别  $c$ ,从其样本集合中随机选取  $M$  个样本作为范例集合  $\mathbf{M}_c$ :

$$\mathbf{M}_c = \{\mathbf{x}_1^{(c)}, \mathbf{x}_2^{(c)}, \dots, \mathbf{x}_M^{(c)}\} \quad (13)$$

在第  $k$  个增量阶段,模型的训练数据  $\mathbf{D}_k^{\text{train}}$  在  $\mathbf{M}_c$  基础上增加新增类别的训练标本,表示为:

$$\mathbf{D}_k^{\text{train}} = \mathbf{D}_k^{\text{new}} \cup \bigcup_{c \in \mathbf{y}_{k-1}} \mathbf{M}_c \quad (14)$$

式中:  $\mathbf{D}_k^{\text{new}}$  表示当前阶段新增类别的训练样本;  $\mathbf{M}_c$  是从历史阶段保留下来的记忆样本。

尽管随机采样策略在理论上不保证范例的最优性,但其具有实现简单、计算开销低、与模型结构解耦等优势,尤其适用于本文研究多阶段、长序列、类增量的大模型持续学习任务。

### 1.4 基于 LoRA 的 LLM 语义对齐

为了实现从振动信号的数值特征到自然语言诊断决策的跨越,利用通用大语言模型 (本文选择 Qwen) 作为解码器,并通过参数高效微调实现领域适配<sup>[22]</sup>。由于 LLM 无法直接处理连续振动特征,研究中设计一个轻量级的线性投影层,将 WDCNN 提取的维度特征向量  $\mathbf{z}$  映射到 LLM 的词嵌入空间维度,表示为:

$$\mathbf{E}_{\text{vib}} = \mathbf{W}_{\text{proj}} \cdot \mathbf{z} + \mathbf{b}_{\text{proj}} \quad (15)$$

式中:  $\mathbf{E}_{\text{vib}}$  表示映射后的向量;  $\mathbf{W}_{\text{proj}}$  和  $\mathbf{b}_{\text{proj}}$  分别表示线性投影层的权重和偏置项。映射后的向量  $\mathbf{E}_{\text{vib}}$  被封装在特殊标记中 (本文置于  $\langle \text{signal} \rangle$  和  $\langle / \text{signal} \rangle$  之间),作为一

种特殊的视觉令牌序列嵌入到文本提示中,从而实现信息的早期融合。

同时,考虑到全参数微调 LLM 的高昂计算成本,采用 LoRA 微调策略。冻结预训练 LLM 的部分参数  $\Phi_0$ ,仅在注意力层的查询矩阵  $W_q$  和值矩阵  $W_v$  引入可训练的低秩分解矩阵。具体而言,对于每一层注意力权重  $W \in \{W_q, W_v\}$ ,将参数更新量  $\Delta W$  约束为两个低秩矩阵的乘积:

$$\Delta W = BA \quad (16)$$

式中:  $B \in \mathbf{R}^{d \times r}$  初始化为零矩阵,  $A \in \mathbf{R}^{r \times d}$  采用高斯分布随机初始化,且  $r < d$  为秩的大小。因此,修正后的前向传播过程包含原预训练路径与旁路更新两部分。对于输入特征  $x$ ,修正后的查询向量  $Q$  和值向量  $V$  计算如下:

$$\begin{cases} Q = x \left( W_q + \frac{\alpha}{r} B_q A_q \right) \\ V = x \left( W_v + \frac{\alpha}{r} B_v A_v \right) \end{cases} \quad (17)$$

式中:  $\alpha$  为缩放系数,主要用于平衡预训练特征与适应性特征的贡献。

在训练阶段,将 WDCNN 提取并经过对齐层映射的振动特征嵌入  $E_{vib}$  与文本提示指令  $I$  拼接。模型优化的目标是最大化目标诊断维护决策  $Y = \{y_1, y_2, \dots, y_L\}$  的生成概率。通过最小化如下的负对数似然损失  $\mathcal{L}$  来实现这一目标:

$$\mathcal{L} = - \sum_{i=1}^L \log P(y_i | y_{<i}, I, E_{vib}, \Phi_0, A, B) \quad (18)$$

式中:  $y_{<i}$  表示当前时刻之前的上下文标记序列。该目标函数使得模型在保持  $\Phi_0$  冻结的情况下,驱动  $A, B$  以及对齐层参数进行协同更新,从而使得 LLM 具备理解设备振动语义并生成诊断维护决策结果的能力。

### 1.5 基于 CL-LLM 的诊断维护决策流程

根据以上构建的 CL-LLM,将其应用于设备增量故障诊断维护决策,具体步骤如下。

步骤 1) 特征提取。原始振动信号在感知层通过基于 MECS 的 WDCNN 提取特征,其中 MECS 注意力模块通过多尺度空间门控与通道门控自适应聚焦关键故障频段,输出高判别性特征向量。

步骤 2) 桥接。特征向量在对齐和存储层输入线性分类器进行故障分类与模态对齐,通过随机采样策略管理记忆库,在类增量过程中融合新旧样本特征以稳定持续学习的知识表示。

步骤 3) 推理与生成。对齐后的特征进入认知层,驱动由 LoRA 适配轻量微调冻结的 LLM,持续学习得到故障诊断结果,生成维护决策结果。

## 2 实验验证

### 2.1 实验数据获取

为了验证所提出 CL-LLM 的有效性,在面向设备运维的公共数据集和自有试验台上进行测试。公共数据集采用美国凯斯西储大学(Case Western Reserve University, CWRU)公开的轴承数据集<sup>[23]</sup>,该数据集在 4 种负载条件(0~3 HP)(1 HP  $\approx$  735 W)进行采集,由 12 kHz 采样频率下的正常轴承、内圈故障轴承、外圈故障轴承及滚动体故障轴承的振动信号构成,详细的数据集和类增量诊断实验任务(T0~T3)设置如表 1 所示。为了验证大模型在少样本和不平衡样本条件下的泛化能力,训练集分别为少样本(200/20)和不平衡样本(200/50/30/10)两种设置。

表 1 CWRU 轴承公开数据集实验任务设置  
Table 1 Task settings of CWRU bearing dataset

| 任务 | 模式    | 程度/in | 类别 | 训练集   | 测试集 |
|----|-------|-------|----|-------|-----|
| T0 | 正常    | —     | C0 | 200   | 200 |
|    | 滚动体故障 | 0.007 | C1 | 200   | 200 |
|    | 内圈故障  | 0.007 | C2 | 200   | 200 |
|    | 外圈故障  | 0.007 | C3 | 200   | 200 |
| T1 | 滚动体故障 | 0.014 | C4 | 20/50 | 200 |
|    | 内圈故障  | 0.014 | C5 | 20/50 | 200 |
| T2 | 滚动体故障 | 0.021 | C6 | 20/30 | 200 |
|    | 外圈故障  | 0.014 | C7 | 20/30 | 200 |
| T3 | 内圈故障  | 0.021 | C8 | 20/10 | 200 |
|    | 外圈故障  | 0.021 | C9 | 20/10 | 200 |

除了 CWRU 公共数据集测试,研究还在自有的齿轮箱故障诊断试验台上进行了验证<sup>[24]</sup>。该试验台如图 3 所示,主要由控制器、齿轮箱、电机、负载等装置组成。本文实验在转速为 50 Hz,负载为 0.1 A 的条件下采集振动信号,采样时间为 10 s。以 25.6 kHz 的采样频率采集了包括单齿点蚀、单齿裂纹、双齿点蚀、双齿裂纹 4 种故障类型以及正常齿轮的振动信号。详细的实验设置如表 2 所示,同样设置了少样本(50/20)和不平衡样本(50/25/15/5)场景。

### 2.2 CL-LLM 的网络参数设置

实验中,CL-LLM 特征提取器的网络结构如表 3 所示。该网络以原始振动信号作为输入,依次经过 5 个核心层级处理。每层均采用包含宽卷积核与小卷积核的一维卷积提取局部特征,接着通过一维最大池化进行降采样,并利用一维 MECS 进行特征筛选与增强。在处理




图 3 齿轮箱故障诊断实验台

Fig. 3 Gearbox test bench for fault diagnosis

表 2 自有齿轮箱增量诊断维护决策实验设置

Table 2 Task settings for the self-owned gearbox experiments

| 任务 | 模式     | 程度/mm | 类别 | 训练集   | 测试集 |
|----|--------|-------|----|-------|-----|
| T0 | 正常     | —     | C0 | 50    | 40  |
|    | 单齿点蚀故障 | 3 点   | C1 | 50    | 40  |
|    | 单齿点蚀故障 | 6 点   | C2 | 50    | 40  |
|    | 单齿点蚀故障 | 9 点   | C3 | 50    | 40  |
| T1 | 单齿裂纹故障 | 深 0.5 | C4 | 20/25 | 40  |
|    | 单齿裂纹故障 | 深 2   | C5 | 20/25 | 40  |
| T2 | 双齿点蚀故障 | 3 点   | C6 | 20/15 | 40  |
|    | 双齿点蚀故障 | 6 点   | C7 | 20/15 | 40  |
| T3 | 双齿裂纹故障 | 深 0.5 | C8 | 20/5  | 40  |
|    | 双齿裂纹故障 | 深 1   | C9 | 20/5  | 40  |

过程中,特征维度逐步演变,通道数从 16 逐层增加至 64,序列长度则由 2 048 逐步压缩至 4。之后,特征被展平为 256 维向量,通过全连接层映射到 1 024 维特征空间,最终由线性输出层生成对应类别数的分类结果,从而完整实现了从振动信号到面向高效诊断维护决策的特征提取。

为将实验中提取的特征接入大语言模型,设计了专用的对齐网络。该网络首先通过一个带有 ReLU 激活的线性层将 1 024 维特征降至 128 维,再通过第 2 个线性层将其投影并展宽为 7 680 维,最后通过重塑操作,将其结构化为一个包括 5 个令牌、每个令牌维度 1 536 的序列。这一步将传统神经网络的特征向量转换成通用大语言模型能直接理解和处理的标准化令牌序列格式。

在实验过程中,CL-LLM 的训练分为 3 个阶段,其超参数配置如表 4 所示。首先,在基础任务上使用较高的学习率对特征提取器进行全参数预训练,使其掌握通用的特征提取能力。其次,在增量任务阶段以极低的学习

表 3 所提出特征提取器的网络结构参数

Table 3 The network structure of the proposed model

| 结构     | 过滤器 | 核  | 步幅 | 填充 |
|--------|-----|----|----|----|
| 原始信号   | 1   | —  | —  | —  |
| 一维卷积层  | 16  | 64 | 16 | 24 |
| 最大池化层  | —   | 2  | 2  | 0  |
| MECS 层 | 16  | —  | —  | —  |
| 一维卷积层  | 32  | 3  | 1  | 1  |
| 最大池化层  | —   | 2  | 2  | 0  |
| MECS 层 | 32  | —  | —  | —  |
| 一维卷积层  | 64  | 3  | 1  | 1  |
| 最大池化层  | —   | 2  | 2  | 0  |
| MECS 层 | 64  | —  | —  | —  |
| 一维卷积层  | 64  | 3  | 1  | 1  |
| 最大池化层  | —   | 2  | 2  | 0  |
| MECS 层 | 64  | —  | —  | —  |
| 一维卷积层  | 64  | 3  | 1  | 1  |
| 最大池化层  | —   | 2  | 2  | 0  |
| MECS 层 | 64  | —  | —  | —  |
| 展平层    | —   | —  | —  | —  |
| 全连接层   | —   | —  | —  | —  |
| 线性输出层  | —   | —  | —  | —  |

表 4 CL-LLM 训练参数设置

Table 4 Hyperparameter setting for CL-LLM

| 参数项    | 预训练   | 增量微调    | LLM 微调                      |
|--------|-------|---------|-----------------------------|
| 模型对象   | WDCNN | WDCNN   | Qwen-1.5B                   |
| 优化器    | Adam  | Adam    | AdamW                       |
| 学习率    | 0.001 | 0.000 1 | 0.000 1                     |
| 批大小    | 64    | 64      | 1                           |
| 迭代次数   | 50    | 300     | 10                          |
| 学习率调度器 |       |         | Cosine                      |
| 微调策略   | 全参数   | 全参数     | LoRA( Rank = 4, Alpha = 32) |
| 最大序列长度 |       |         | 1 536                       |

率对该特征提取网络进行微调,使其适应新的任务数据,同时保持其核心表征的稳定性。最后,将前两个阶段训练好的、能输出对齐后令牌序列的网络作为固定特征提供者,使用 LoRA 微调配合 AdamW 优化器和余弦学习率调度器,对 Qwen-1.5B 大模型进行适配微调,最终构建出能够融合振动信号深度特征与语言模型语义理解能力的持续学习大模型。

## 2.3 对比模型与评估指标

为了评估所提出方法的性能,在两个实验中比较了如下6种不同的模型:1)卷积神经网络(convolutional neural network, CNN)<sup>[25]</sup>;2)CNN与残差网络(residual network, ResNet)组合<sup>[26]</sup>;3)CNN与压缩和激励注意力机制(squeeze-and-excitation attention mechanism, SEAM)组合;4)压缩和激励注意力机制与残差网络结合(squeeze-and-excitation attention mechanism and residual network, SEResnet)<sup>[27]</sup>;5)CNN与改进残差网络的组合(improved residual network, IRN)<sup>[26]</sup>;6)本文提出的CL-LLM模型。前述5个对比模型可以比较类增量故障诊断的性能,而仅有CL-LLM可以生成维护决策结果。所以实验中首先量化对比少样本条件下的持续学习故障诊断性能,然后量化比较不平衡条件下的持续学习故障诊断性能,最后定性分析了CL-LLM生成的维护决策结果。

为定量评估持续学习大模型的性能,采用准确率(精度)来分析故障诊断性能,采用遗忘率来分析持续学习性能。准确率用正确识别出具体故障类型的比例来表示,而平均遗忘率 $F$ 的计算公式为:

$$F = \frac{1}{N-1} \sum_{i=1}^{N-1} (A_{i,i} - A_{N,i}) \quad (19)$$

式中: $N$ 表示持续学习总任务量; $A_{i,i}$ 表示第 $i$ 个任务完成训练时,该任务自身的分类准确率; $A_{N,i}$ 表示所有 $N$ 个任务全部训练结束后,第 $i$ 个任务的测试准确率。

## 3 结果与讨论

### 3.1 少样本条件下的持续学习故障诊断性能评估

为分析不同样本长度对少样本持续学习性能的影响,所提出的CL-LLM在CWRU轴承数据集与自有齿轮箱试验台上、在不同样本长度下的增量诊断输出结果如图4所示。由图4(a)可知,在CWRU轴承数据集上测试的少样本(200/20)增量故障诊断性能随样本长度增加呈现显著的上升趋势。当样本长度从512增至4 096时,CL-LLM在增量任务(T1~T3)及整体平均值上的诊断准确率均有明显提升。尤其在较长样本长度(2 048、4 096)条件下,CL-LLM不仅在首个任务(T0)上保持接近1的诊断结果,在后续任务上也展现出较强的持续学习能力,整体平均值最高达到0.9以上。这表明在标准化的公共数据集上,充分长的振动信号能够提供更完整、更稳定的故障特征,有效支撑CL-LLM在增量场景下的判别与泛化。

如图4(b)所示,对自有齿轮箱试验台上进行少样本(50/20)增量故障诊断,CL-LLM的性能与样本长度的关系呈现出相似的特点。在短样本长度(128, 256)条件下,CL-LLM在所有任务上的准确率均相对较低,尤其在后续




图4 不同样本长度在少样本类增量任务中的表现

Fig.4 The performance of different sample lengths in class incremental tasks for few-shot samples

任务中表现下滑明显。随着样本长度增加至512和1 024,CL-LLM在T0任务及后续任务上的性能均获得显著提升,整体平均值最高达到约0.9。值得关注的是,在样本长度达到1 024时,模型在T1~T3任务上的表现甚至出现稳步提升的趋势,说明在更复杂、噪声更明显的实际齿轮箱试验台数据中,足够长的样本有助于提取更具区分度的时频特征,从而支持CL-LLM在增量诊断过程中逐步适应并维持较高的分类稳定性。

图5所示为CL-LLM在CWRU数据集上采用最优样本长度(4 096)进行类增量诊断的具体混淆矩阵结果。在初始阶段(T0任务和C0~C3类别),CL-LLM实现了完美的诊断,所有故障类别均被准确诊断。随着新故障类别的逐阶段引入,CL-LLM展现出强大的知识保持能力。在增量诊断阶段1(T1任务和C0~C5类别),绝大多数原有类别和新类别仍能保持接近完美的分类准确率。进入增量诊断阶段2(T2任务和C0~C7类别)和阶段3(T3任务和C0~C9类别)后,部分类别间开始出现少量的诊断混淆。例如C1与C7、C4与C6等故障类别之间存在有限的对角线外散布。但在整体上,CL-LLM保持了以对角线为主导的清晰结构,主对角线数值(各类别的正确分类数)在持续学习过程中均占据绝对主导地位,而非对角线上的误判值始终维持在较低水平。这表明CL-LLM在持续学习新任务时,对已学类别依然保持着较高的整体识别精度和稳健的分类边界。





图 5 CL-LLM 在 CWRU 数据集上的小样本持续学习混淆矩阵

Fig. 5 Confusion metrics of few-shot continuous learning by CL-LLM on CWRU dataset

根据齿轮箱增量故障诊断实验获得的最优样本长度 (1 024), 类增量诊断混淆矩阵结果如图 6 所示。在初始阶段 (T0 任务和 C0~C3 类别), CL-LLM 对新类别实现了高精度分类, 仅出现极个别误判。随着诊断任务的推进, 模型在增量诊断阶段 1 (T1 任务和 C0~C5 类别) 中依然保持了对绝大多数类别的强识别能力, 主对角线数值普遍接近或达到每类 40 个样本的满额。尽管在阶段 2 及后续阶段中, 部分复杂类别如 C6 和 C7 类别) 开始出现一定程度的类间混淆, 表现为非对角线上的零星分布, 但整体分类结构仍以清晰的决策边界为主导。这表明, 即使面对更复杂的齿轮箱试验台, 所提大模型在充分长的

样本支持下, 仍能有效维持持续学习过程中的分类稳定性, 为后续在更严苛数据条件下的抗遗忘分析提供了可靠的性能基础。

为了进一步评估 CL-LLM 的增量故障诊断能力, 本文大模型与前述对比模型进行公平对比, 结果如图 7 所示。由图 7(a) 可知, 本文模型在从 T0~T3 的 4 个类增量故障诊断阶段和整体平均值上均取得了领先的持续学习性能。特别是在后续任务 T1 和 T2 中, 其准确率 (0.985 0 和 0.911 2) 显著高于所有对比方法。相对应的是, 所有对比模型在这些后续任务阶段普遍出现显著的性能下降。在最终任务 T3 中, CL-LLM 更是取得了






图 6 CL-LLM 在齿轮箱试验台上的小样本持续学习混淆矩阵

Fig. 6 Confusion metrics of few-shot continuous learning by CL-LLM on gearbox test rig




图 7 少样本类增量故障诊断的模型对比

Fig. 7 Model comparison for class incremental fault diagnosis using few-shot samples

0.926 5 的优异表现,其整体平均诊断精度达到 0.955 7,充分证明了所提方法在公共数据集上具有卓越的持续学习能力。

在齿轮箱试验台的少样本类增量故障诊断对比过程中,CL-LLM 同样展现出显著的竞争力。由图 7(b)可知,在初始任务 T0 和最终任务 T3 中,CL-LLM 分别取得了 0.975 0 和 0.850 0 的诊断准确率,均处于对比模型前列。在任务 T1 中,其诊断精度(0.970 8)仅次于 SEAM(0.974 4),但明显优于其他对比模型。尽管在任务 T2 中性能出现一定波动(0.825 0),但 CL-LLM 在整体平均

精度上仍达到 0.905 2,在对比模型保持领先。这反映了在更复杂的实际齿轮箱增量故障诊断中,本文提出的 CL-LLM 仍能保持总体稳定的持续学习性能。当模型面对更具挑战性的数据分布时,其稳健性尚有进一步提升的空间。

不同模型在两种数据集上持续学习的遗忘率曲线如图 8 所示。




图 8 不同对比模型的遗忘率曲线对比

Fig. 8 Comparison of forgetting rate curves for different models

在 CWRU 数据集上的遗忘率计算结果表明,本文提出的 CL-LLM 在持续学习过程中具有最强的抗遗忘能

力,其平均遗忘率仅为 0.024 5,显著低于所有对比模型。由图 8(a)可知,其他方法如 CNN(0.079)、SEAM(0.110 2)和 IRN(0.147 4)均表现出不同程度的性能下降,而 ResNet(0.176 2)与 SEResnet(0.184 3)的遗忘尤为明显。CL-LLM 在最终任务 T3 上甚至出现了精度的小幅回升,即下降率为负,体现了大模型学习到的特征具有良好的泛化与正向迁移能力。整体而言,该结果验证了所提的 CL-LLM 在标准轴承增量故障诊断场景下,能够有效稳定知识表征,显著缓解因持续学习新类别而导致的灾难性遗忘问题。

由图 8(b)可以看出,CL-LLM 的遗忘率曲线在整个持续学习过程中最为平缓且稳定,仅在 T2 阶段出现轻微的性能波动。在任务 T1 和 T3 阶段,CL-LLM 几乎保持了所有已学知识,遗忘率趋近于 0。相较之下,CNN 和 SEResnet 的遗忘率曲线呈现出明显的阶梯式下降,表明其在学习新类别时对历史知识的遗忘较为严重。SEAM 与 ResNet 虽然前期下降较缓,但在后续任务中遗忘加速。而 IRN 方法虽整体表现较好,但其遗忘曲线的波动幅度大于所有的对比模型。该结果进一步表明,即使在少样本的齿轮箱试验台场景下,提出的 CL-LLM 依然能够有效缓解灾难性遗忘,实现稳定的持续学习。

3.2 不平衡样本条件下的持续学习故障诊断性能评估

在前述少样本条件下持续学习性能评估基础上,进一步考察实际工业场景中更普遍的不平衡数据分布对持续学习的影响。为节约篇幅,后文仅以 CWRU 轴承数据集为例。在持续学习实验过程中,采用不同样本长度时,CL-LLM 在不平衡类增量故障诊断任务中的性能表现如图 9 所示。随着样本长度从 512 增加至 4 096,CL-LLM 在从 T0~T3 的 4 个增量阶段及整体平均值上的准确率均呈现明显的提升趋势。在较短的 512 样本长度条件下,CL-LLM 在后续任务 T2 和 T3 上的诊断性能衰退较为显著(0.656 2 和 0.591 5)。而当样本长度达到 4 096 时,模型不仅在所有增量阶段均维持了高精度,其整体平均值也达到最优的 0.959 7。这表明充分的样本长度能有

效缓解类别不平衡所带来的持续学习不稳定性,支撑 CL-LLM 在类增量过程中保持强健的故障诊断能力。






图9 不同样本长度在 CWRU 数据集不平衡类增量任务中的表现

Fig. 9 The performance of different sample lengths in imbalanced-class incremental diagnosis tasks for CWRU dataset

本文所提出的 CL-LLM 在 CWRU 数据集上进行不平衡类增量诊断结果的混淆矩阵如图 10 所示。在初始阶段 T0,CL-LLM 对 4 个基础类别实现了完美区分。随着不平衡新类别的逐步加入,CL-LLM 在增量阶段 T1 和 T2 中仍保持了以对角线为主导的清晰结构,绝大多数样本被正确分类,仅在新旧类别之间存在零星且有限的误判,例如在 T2 任务中对 C1 与 C7 类故障出现部分诊断混淆。到最终阶段 T3,面对共 10 个类别的不平衡分布,模型的主对角线数值依然普遍较高,尽管部分类别如 C1 和 C7 故障的混淆有所增加,但整体分类结构稳健。这表明,即使在类别样本数量不平衡的严峻条件下,所提出的大模型仍能有效维持对历史类别的识别能力,并持续学习新类别,展现出良好的增量诊断鲁棒性。

为全面评估 CL-LLM 对不平衡增量故障诊断的综合性能,将其与前述对比模型进行了比较。在 CWRU 轴承数据集上,各模型在不平衡类增量故障诊断任务中的表现如图 11 所示。从图 11 可以看出,提出的 CL-LLM 在从 T0~T3 的所有增量阶段及整体平均值上均取得最优性能,其平均精度高达 0.959 7,显著领先于其他对比模型。尤其在从 T1~T3 的后续任务中,CL-LLM 诊断精






图 10 CL-LLM 在 CWRU 上的不平衡类增量诊断混淆矩阵

Fig. 10 Confusion metrics of imbalanced-class incremental diagnosis by CL-LLM on CWRU dataset




图 11 在 CWRU 数据集上不平衡类增量故障诊断的模型对比

Fig. 11 Model comparison for imbalanced-class incremental fault diagnosis using CWRU dataset




图 12 不同模型的遗忘率曲线对比

Fig. 12 Comparison of forgetting rate curves for different models

度稳定在 0.925 0 以上,而其他对比模型全部出现明显的性能波动或下降。这表明 CL-LLM 在面对类别不平衡时,仍能有效维持高精度且稳定的持续学习能力。

为进一步揭示各模型在不平衡持续学习中的知识保留能力,对其遗忘率进行了量化分析。在 CWRU 数据集实验中,各模型在不平衡类增量故障诊断任务的遗忘率曲线对比如图 12 所示。CL-LLM 在 3 个增量阶段均保持了极低的遗忘率,其平均遗忘率仅为 0.024 8,显著低于所有对比模型。其他模型如 CNN、ResNet、SEAM 等的平均遗忘率均在 0.09 以上,且在中间任务 T2 普遍出现明显的遗忘峰值。这表明在类别不平衡的 CWRU 增量故障诊断任务中,CL-LLM 能够最有效地缓解灾难性遗忘,维持知识的长期稳定性。

3.3 消融实验分析

为剖析 CL-LLM 内部关键组件的贡献,继续在 CWRU 数据集上设计并进行了系统的消融实验,结果如表 5 所示。该消融实验在样本分布为 200-50-30-10 的不平衡增量设置下,评估了多尺度卷积(多尺度)、注意

| 表 5 不平衡类增量条件下 CWRU 数据集消融实验结果                                                                 |     |     |      |    |                |                |                |
|----------------------------------------------------------------------------------------------|-----|-----|------|----|----------------|----------------|----------------|
| Table 5 Ablation study results of imbalanced-class incremental diagnosis on the CWRU dataset |     |     |      |    |                |                |                |
| 变体                                                                                           | 多尺度 | 注意力 | 融合   | T0 | T1             | T2             | T3             |
| B0                                                                                           | ×   | ×   | ×    | 1  | 0.971 7        | 0.901 9        | 0.865 0        |
| B1                                                                                           | ×   | ×   | Add  | 1  | <b>0.996 7</b> | 0.877 5        | 0.891 9        |
| B2                                                                                           | ✓   | ×   | Add  | 1  | 0.981 7        | 0.934 4        | 0.920 0        |
| B3                                                                                           | ×   | ✓   | Add  | 1  | 0.980 8        | 0.893 8        | 0.884 4        |
| B4                                                                                           | ×   | ✓   | Gate | 1  | 0.989 2        | 0.879 4        | 0.903 5        |
| B5                                                                                           | ✓   | ✓   | Add  | 1  | 0.993 3        | 0.888 8        | 0.865 5        |
| CL-LLM                                                                                       | ✓   | ✓   | Gate | 1  | 0.987 5        | <b>0.925 6</b> | <b>0.925 5</b> |

注: Add 表示逐元素相加; Gate 表示逐元素相乘。

实验结果表明,完整的 CL-LLM 模型在增量任务 T2 和 T3 上取得了最优的精度(0.925 6 和 0.925 5),体现了

其最佳的持续学习稳定性。通过对比各消融变体可以发现,引入多尺度卷积(对比 B1 与 B2,B3 与 B5 消融变体)显著提升了模型在任务 T2 上的表现,说明其增强了特征的丰富性与泛化能力。而引入门控注意力融合机制(对比 B3 与 B4,B5 与 B6 消融变体)则有效改善了任务 T3 的精度,证明了该机制在缓解后期遗忘方面的关键作用。此外,仅使用简单相加融合的单尺度注意力模型(B3 消融变体)在任务 T1 后性能衰退明显,这凸显了多尺度特征提取与自适应门控融合策略协同作用的必要性。综上,多尺度特征提取与门控注意力融合策略协同作用,共同构成了大模型在不平衡持续学习中保持高精度的核心机制。

表 6 CL-LLM 输出的 CWRU 数据集不同故障程度的维护决策结果

Table 6 Maintenance decisions for different levels of faults in CWRU dataset generated by CL-LLM

| 标签 | 程度 | 故障描述              | 维护决策结果                                            |
|----|----|-------------------|---------------------------------------------------|
| C0 | -  | 轴承运行平稳,无异常振动      | 保持现状;继续执行常规巡检计划,记录运行数据作为基准,无需额外操作                 |
| C1 | 轻度 | 滚动体表面出现微小点蚀       | 加强监测;缩短巡检周期,检查润滑脂是否污染或变质。建议清洗并重新润滑,继续观察振动趋势       |
| C4 | 中度 | 滚动体点蚀扩大,伴有轻微剥落    | 计划维修;轴承已出现明显磨损。建议在下一次计划停机时更换轴承。目前可适当降低负载或转速运行     |
| C6 | 重度 | 滚动体严重剥落,可能导致保持架断裂 | 立即停机;存在抱死或破碎风险。必须立即停止运行并更换轴承,同时检查润滑系统是否存在金属碎屑     |
| C2 | 轻度 | 内圈滚道出现早期疲劳剥落      | 检查对中;检查轴与轴承内圈的配合情况,排查是否存在轴不对中或安装不当,密切监测 BPFI 频率幅值 |
| C5 | 中度 | 内圈剥落面积增大,振动加剧     | 准备备件;轴承寿命已接近尾声。安排在两周内进行更换。检查轴径表面是否有磨损,防止跑内圈       |
| C8 | 重度 | 内圈滚道严重损坏,甚至开裂     | 紧急维护;立即停机更换。拆卸后需仔细检查轴颈尺寸精度,评估是否需要修复轴表面            |
| C3 | 轻度 | 外圈滚道承载区出现轻微磨损     | 听诊检查;使用听诊棒检查是否有异响。检查轴承座孔配合是否过松,紧固底座螺栓             |
| C7 | 中度 | 外圈损伤扩展,出现明显周期性冲击  | 择期更换;根据生产计划尽快安排更换。检查轴承座是否存在变形或共振现象                |
| C9 | 重度 | 外圈大面积剥落,振动极不稳定    | 强制停机;防止损坏轴承座或整机。更换轴承时,务必检查轴承座孔的圆柱度,必要时更换轴承座       |

4 结 论

针对设备增量故障诊断维护决策的持续学习需求,提出并构建了一个持续学习大语言模型 CL-LLM,系统地解决了少样本、类别不平衡及灾难性遗忘等挑战。所提出的 CL-LLM 采用基于 MECS 的 WDCNN 实现多尺度故障特征的自适应提取,结合随机记忆回放与可扩展分类器增强历史知识的保持能力,并利用基于 LoRA 的信号-文本对齐机制,实现振动特征到诊断维护语义的跨模态映射。在 CWRU 公开数据集与自有的齿轮箱试验台上进行增量故障诊断和维护决策实验,结果表明,CL-LLM

3.4 维护决策实验结果

以基于 CWRU 数据集的增量故障诊断维护决策为例,表 6 为 CL-LLM 输出的完整的维护决策结果,可以看出 CL-LLM 将增量故障诊断输出与具体的维护决策进行了映射。表中不仅准确描述了从轻度到重度不同等级的滚动体、内圈和外圈故障特征,更重要的是,为每种故障状态都提供了清晰、可操作的维护指导。例如从加强监测到计划维修,再到立即停机的逐级响应策略。这实现了从算法诊断结果到实际维护决策的闭环,将人工智能的感知能力有效转化为了工程实践中的生产力,显著提升了设备运维的精准性与时效性。

在持续学习新故障类别过程中,能够显著维持高诊断精度、降低遗忘程度,并具备生成可解释的维护决策结果的能力。研究不仅验证了持续学习大模型在增量故障诊断维护决策中的有效性,也为构建下一代智能运维系统提供了可行的路径。未来工作将进一步探索在跨工况、跨设备场景下的大模型泛化能力与部署效率优化。

参考文献

[ 1 ] 刘大同,严如强,苗强,等. 跨界赋能,探索大模型在测量与仪器中的融合应用与系统创新[J]. 仪器仪表学报,2025,46(10):1.

Liu Datong, Yan Ruqiang, Miao Qiang, et al. Cross-boundary empowerment: Exploring the fusion application

- and system innovation of large models in measurement and instruments [J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 1.
- [2] 彭宇,季拓,郭楚亮.故障预测与健康管理领域大语言模型:应用与展望[J].仪器仪表学报,2025,46(10): 2-21.  
Peng Yu, Ji Tuo, Guo Chuliang. Large language models for prognostics and health management: Applications and prospects[J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 2-21.
- [3] Zhang Y, Han D Y, Xu X F, et al. Debaised prototype network with relaxed contrastive distillation strategy for rotating machinery few-shot domain incremental fault diagnosis [J]. Knowledge-Based Systems, 2026, 333: 115117.
- [4] Guo Z, Du W L, Li C, et al. Fault diagnosis of rotating machinery with high-dimensional imbalance samples based on wavelet random forest [J]. Measurement, 2025, 248: 116936.
- [5] Guo Z, Du W L, Liu Z P, et al. Few-shot sample multi-class incremental fault diagnosis for gearbox based on convolutional-attention fusion network [J]. Expert Systems with Applications, 2025, 264: 125918.
- [6] Ma C J, Yan P, Wang B C, et al. Multi-domain coupled dynamics modeling and enhanced meta-transfer learning method for few-shot fault diagnosis of axial piston pumps[J]. Advanced Engineering Informatics, 2026, 69: 104002.
- [7] Ma W G, Liu R Q, Guo J, et al. A collaborative central domain adaptation approach with multi-order graph embedding for bearing fault diagnosis under few-shot samples [J]. Applied Soft Computing, 2023, 140: 110243.
- [8] Li G Q, Liu Q J, Chen Z Y, et al. Intelligent fault diagnosis of rotating machinery driven by physical information and contrastive learning under extreme sample imbalance conditions [J]. Measurement Science and Technology, 2025, 36(10): 106132.
- [9] Shi M K, Ding C C, Wang R, et al. Graph embedding deep broad learning system for data imbalance fault diagnosis of rotating machinery [J]. Reliability Engineering & System Safety, 2023, 240: 109601.
- [10] 王报祥,丁传仓,居淼,等.面向数据不均衡下机械智能故障诊断的改进循环一致生成对抗网络[J].仪器仪表学报,2025,46(10):96-106.  
Wang Baoxiang, Ding Chuancang, Ju Miao, et al. Improved cycle-consistent generative adversarial network for intelligent mechanical fault diagnosis under imbalanced data[J]. Chinese Journal of Scientific Instrument, 2025, 46(10): 96-106.
- [11] 王玉静,叶柏宏,康守强,等.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[J].仪器仪表学报,2025,46(6):317-329.  
Wang Yujing, Ye Baihong, Kang Shouqiang, et al. A fault diagnosis method for harmonic reducers based on federated learning under multi-source imbalanced data[J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 317-329.
- [12] 石明宽,丁传仓,王锐,等.面向变工况下工业流数据故障诊断的持续迁移学习系统[J].仪器仪表学报,2024,45(4):10-16.  
Shi Mingkuan, Ding Chuancang, Wang Rui, et al. A continuous transfer learning system for fault diagnosis of industrial streaming data under varying working conditions[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 10-16.
- [13] Zheng X B, Cheng Z Y, Cheng J S, et al. Blaschke learning machine: A novel and efficient continual learning classifier toward intelligent fault diagnosis [J]. Mechanical Systems and Signal Processing, 2025, 239: 113350.
- [14] Du W L, Yu X L, Guo Z, et al. Channel attention residual transfer learning with LLM fine-tuning for few-shot fault diagnosis in autonomous underwater vehicle propellers[J]. Ocean Engineering, 2025, 330: 121237.
- [15] Zhang X, Liu S X, Jiang L, et al. FSAMLM: A few-shot adaptation multimodal large model for cross-domain fault diagnosis [J]. Applied Soft Computing, 2025, 185: 113985.
- [16] 黄金凤,王成城,何宏亮,等.思维链范式智能运维文本基多模态智能体[J].机械工程学报,2025,61(23): 58-74.  
Huang Jinfeng, Wang Chengcheng, He Hongliang, et al. Thinking chain paradigm: Text-based multimodal intelligent agent for intelligent operations and maintenance [J]. Journal of Mechanical Engineering, 2025, 61(23): 58-74.
- [17] Xiao C Y, Liu X W, Wulamu A, et al. KG-SR-LLM: Knowledge-guided semantic representation and large language model framework for cross-domain bearing fault diagnosis[J]. Sensors, 2025, 25(18): 5758.
- [18] Van De Ven G, Tuytelaars T, Tolias A. Three types of incremental learning[J]. Nature Machine Intelligence, 2022, 4(12): 1185-1197.
- [19] 蓝金辉,王迪,申小盼.卷积神经网络在视觉图像检测

- 的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.
- Lan Jinhui, Wang Di, Shen Xiaopan. Research progress of convolutional neural networks in visual image detection[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [20] Wang L, Chen D L, Mao Y F, et al. A zero-shot attribute-embedded model with a feature difference mapping sigmoid function for compound fault diagnosis of rotating machinery[J]. ISA Transactions, 2025, 157: 451-465.
- [21] Shen C Q, Liu Y, Chen B J, et al. Decoupling incremental classifier and representation learning based continual learning machinery fault diagnosis framework under long-tailed distribution[J]. Chinese Journal of Mechanical Engineering, 2026, 39: 100031.
- [22] Peng H T, Gao J, Liu J W, et al. A unified rotating machinery health management framework leveraging large language models for diverse components, conditions, and tasks[J]. Engineering Applications of Artificial Intelligence, 2025, 162: 112544.
- [23] Case Western Reserve University Bearing Data Center. Seeded fault test data[EB/OL]. 2014. [2025-02-20]. <http://csegroups.case.edu/bearingdatacenter/home>.
- [24] Guo Z, Du W L, Li C, et al. Multi-scale wavelet decomposition and feature fusion for rotating machinery fault diagnosis under multi-level class imbalance[J]. Mechanical Systems and Signal Processing, 2025, 240: 113427.
- [25] 米洁, 马超, 周海龙, 等. 物理知识引导的卷积神经网络故障诊断预测方法[J]. 仪器仪表学报, 2025, 46(8): 19-32.
- Mi Jie, Ma Chao, Zhou Hailong, et al. Physics knowledge-guided convolutional neural network for fault diagnosis and prediction[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 19-32.
- [26] 陈志强, 陈旭东, Valente de Oliveira J, 等. 深度学习在设备故障预测与健康管理中应用[J]. 仪器仪表学报, 2019, 40(9): 206-226.
- Chen Zhiqiang, Chen Xudong, Valente de Oliveira J, et al. Application of deep learning in equipment fault prediction and health management[J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 206-226.
- [27] Du W L, Yu X H, Guo Z, et al. Squeeze-and-excitation attention residual learning of propulsion fault features for diagnosing autonomous underwater vehicles[J]. Journal of Field Robotics, 2025, 42(1): 169-179.

### 作者简介



李川(通信作者), 2007年获得重庆大学博士学位后, 先后为加拿大渥太华大学博士后、韩国高丽大学研究教授、香港城市大学高级副研究者、厄瓜多尔慈幼理工大学国家特聘专家、重庆工商大学首席特聘教授, 主要研究方向为智能故障诊断。

E-mail: chuanli@21cn.com

**Li Chuan** (Corresponding author) received his Ph. D. degree from Chongqing University in 2007. He was a postdoctoral fellow at the University of Ottawa, Canada; a research professor at Korea University, South Korea; a senior research associate at City University of Hong Kong, China; and a Prometeo Researcher at Universidad Politecnica Salesiana, Ecuador. He is a Distinguished Chair Professor at Chongqing Technology and Business University. His main research interest is intelligent fault diagnosis.