

中文引用格式:樊晓萱,段礼祥,张娜,等. 基于联合定位密集网络的变载齿轮箱故障特征提取[J]. 中国安全科学学报, 2024, 34(10): 166-173.

英文引用格式:FAN Xiaoxuan, DUAN Lixiang, ZHANG Na, et al. Conjoint localization dense networks for fault feature extraction of variable load gearbox[J]. China Safety Science Journal, 2024, 34(10): 166-173.

基于联合定位密集网络的变载齿轮箱故障特征提取*

樊晓萱^{1,2}, 段礼祥^{**1,2}教授, 张娜^{1,2}, 李兴涛³, 蒋璐朦³

(1 中国石油大学(北京)安全与海洋工程学院,北京 102249;2 应急管理部油气生产安全与应急技术重点实验室,北京 102249;3 中国石油国际勘探开发有限公司,北京 100034)

中图分类号:X941 文献标志码:A DOI: 10.16265/j.cnki.issn1003-3033.2024.10.1296

资助项目:中石油战略合作科技专项(ZLZX2020-05-02)。

【摘要】 为解决变载齿轮箱故障诊断中因冗余特征而导致的脉冲信号提取难题,提出一种基于注意力模块(CAM)的脉冲特征提取方法。首先,设计联合定位CAM,包括2个阶段:第1阶段使用多层感知机建模通道依赖关系,增强与故障相关的关键通道特征;第2阶段通过卷积层学习与故障相关的信号段,结合2个阶段重新校准特征,聚焦关键脉冲特征;然后,基于CAM构建联合定位密集网络(CLDN)的变载齿轮箱故障特征提取方法,CLDN通过自适应地重新校准每一层的特征,进一步提高对脉冲信号的学习和表征能力;最后,将提取到的特征输入Softmax分类器,验证所提方法的特征提取效果。结果表明:相比于Self-Attention等4种注意力机制,CAM的准确率平均提升3.8%,可实现脉冲特征的准确定位;相比于ResNet34等7种诊断方法,CLDN的准确率提升3.7%~14.6%,显著增强故障特征的提取效果。

【关键词】 联合定位密集网络(CLDN); 变载齿轮箱; 故障诊断; 特征提取; 注意力模块(CAM)

Conjoint localization dense networks for fault feature extraction of variable load gearbox

FAN Xiaoxuan^{1,2}, DUAN Lixiang^{1,2}, ZHANG Na^{1,2}, LI Xingtao³, JIANG Lumeng³

(1 College of Safety and Ocean Engineering, China University of Petroleum (Beijing), Beijing 102249, China; 2 Key Laboratory of Oil and Gas Production Safety and Emergency Technology, Ministry of Emergency Management, Beijing 102249, China; 3 China National Oil and Gas Exploration and Development Co., Ltd., Beijing 100034, China)

Abstract: To address the challenge of extracting pulse signals in fault diagnosis of variable-load gearbox caused by redundant features, a pulse feature extraction method based on CAM was proposed. First, a CAM was designed, which consisted of two stages. In the first stage, a multilayer perceptron was used to simulate the channel dependencies and enhanced the important channel features related to faults. In the second stage, the convolutional layers were employed to learn signal segments related to faults. By

* 文章编号:1003-3033(2024)10-0166-08; 收稿日期:2024-06-15; 修稿日期:2024-08-21

** 通信作者:段礼祥(1969—),男,四川泸州人,博士,教授,主要从事安全监测与智能诊断工程方面的研究。E-mail:duanlx@cup.edu.cn。

recalibrating the features in two stages, the module focused on the critical pulse features. Next, based on CAM, this study proposed a CLDN method for extracting fault features in variable-load gearboxes. CLDN further improved the learning and representation of impulse signals by adaptively recalibrating the features at each layer. Finally, the extracted features were fed into a Softmax classifier to validate the feature extraction effect of the proposed method. The results show that CAM's accuracy is on average 3.8% higher than 4 attention mechanisms like Self-Attention, achieving accurate localization of impulse features. Compared with 7 diagnostic methods such as ResNet34, the accuracy of CLDN is 3.7% to 14.6% higher, which significantly enhances the extraction of fault features.

Keywords: conjoint localization dense networks (CLDN); variable-load gearbox; fault diagnosis; feature extraction; conjoint attention module (CAM)

0 引言

齿轮箱作为直升机、风力发电机等众多设备中不可缺少的传动部件,其安全性能备受重视^[1]。齿轮箱结构复杂,且长期承受持续变载作用,因而故障多发,轻则导致机组停机停产,重则可能引发灾难性事故。因此,准确诊断变载齿轮箱故障具有重大安全意义。

在变载齿轮箱产生的信号中,脉冲信号作为反映冲击、间隙等故障行为的关键特征,包含重要故障信息^[2]。当前研究大多通过构建更深层次的网络或设计全新的网络结构来提升故障诊断的效果。例如 LI Jimeng 等^[3]提出反向传播神经网络来提取数据的局部特性;张斌等^[4]构建自适应一维神经网络,以适应振动信号中存在的复杂动态模式;王庆荣等^[5]设计了新颖的双通道交叉密集连接网络,以实现轴承故障的诊断。这些方法依赖于神经网络强大的自适应特征提取能力,取得较好的诊断性能。然而,提取的特征中仍存在大量冗余信息,这些冗余可能掩盖脉冲信号,进而影响故障诊断的准确性。因此,如何有效提升网络性能,以准确提取脉冲信号特征,仍然是一个亟待解决的关键问题。

鉴于此,笔者拟提出 3 个特征优化模块:一阶注意力模块(First-order Attention Module, FAM),二阶注意力模块(Second-order attention module, SAM)和联合定位注意力模块(Conjoint Attention Module, CAM)。FAM 通过多层感知机增强关键通道特征, SAM 利用卷积层定位故障脉冲, CAM 结合二者优化特征映射,获取与故障诊断任务相关的通道和信号段,实现脉冲特征的准确定位,解决变载信号中的特征提取难题;在此基础上,构建联合定位密集网络(Conjoint Localization Dense Networks, CLDN),通过在不同网络深度嵌入 CAM,自适应校准特征,并利

用密集层的特征复用提升网络性能。

1 CLDN 网络故障特征提取方法

定义 1D 卷积变换 F , $F: X \rightarrow X'$, $X \in R^{W \times C}$, $X' \in R^{W' \times C'}$, 其中, X , X' 分别为卷积变换前和变换后的特征向量, W , W' 分别为输入和输出信号段数目, C , C' 分别为输入和输出通道数。可以看到,信号段和通道是输入信号的 2 个不同且同等重要的维度。目前,广泛应用的注意力机制为时间注意力机制^[6]和通道注意力机制^[7]。时间注意力机制能够强化关键信号段,而通道注意力机制则聚焦重要通道。基于对这 2 种机制的启发,笔者提出 CAM 模块,提取关键信号段和通道。并在此基础上构建 CLDN 网络,以增强对脉冲特征的定位能力。

1.1 FAM

不同通道对故障特征的敏感度不同,其中一些通道可能与故障无关,甚至包含虚假信息。为此,设计 FAM 模块,通过建模通道间的相互依赖关系,自适应调整通道的重要性。

定义 FAM 的输入为通道组合 $Y = [y_1, y_2, \dots, y_c]$, 其中, $y_i \in R^{W \times 1}$ 表示第 i 个通道的特征。在卷积运算 $F(\cdot)$ 中,通道信息与信号段信息相互结合。因此, FAM 使用平均池化 Avgpool(\cdot) 将信号段信息压缩,并生成通道统计向量 $z \in R^{1 \times C}$ 。 z 的第 i 个元素为:

$$z_i = \text{Avgpool}(y_i) = \frac{1}{W} \sum_{j=1}^W y_i(j) \quad (1)$$

该操作将局部信号段信息嵌入到 z 中。接下来, FAM 通过多层感知机 (Multilayer Perceptron, MLP) 来建模通道依赖性,并生成通道重校准向量 z' , 定义为:

$$z' = \text{MLP}(z_1, z_2, \dots, z_c) = \sigma(\lambda_2 \cdot \delta(\lambda_1(z))) \quad (2)$$

式中:MLP(·)为全连接操作; λ_1 和 λ_2 均为全连接层的权重矩阵,编码通道依赖性; $\delta(\cdot)$ 为ReLU激活函数; $\sigma(\cdot)$ 为Sigmoid函数,将输入激活向量的动态范围压缩到[0,1],得到通道重校准向量 \mathbf{z}' 。 \mathbf{z}'_i 的值表示第*i*个通道的重要性。 \mathbf{z}' 将特征 \mathbf{Y} 重校准为:

$$\mathbf{M} = \mathbf{Y} \cdot \mathbf{z}' \quad (3)$$

因此,得到的特征 \mathbf{M} 充分考虑了全局信息的指导作用,能够有效地突出特征中的重要通道。

1.2 SAM

当齿轮箱发生局部故障时,故障位置会产生冲击激励,引起接触齿面的强烈振动,并传导至齿轮箱其他部件,使系统在共振频率下产生高频衰减振动。因此,振动信号的脉冲信号段集中反映了故障的内在特性。为此,提出SAM,帮助网络识别与故障相关的信号段,实现脉冲特征的准确定位。

定义SAM的输入为信号段组合 $\mathbf{Y} = [y^1, y^2, \dots, y^w]$, $y^j \in R^{1 \times C}$ 。SAM分别通过平均池化-卷积层(Avgpool+Conv1×1)和最大池化-卷积层(Maxpool+

Conv1×1)压缩通道信息,得到特征 \mathbf{Y} 在信号段上的投影 $s_1, s_2 \in R^{w \times 1}$ 。其中,第*i*个元素定义为:

$$\begin{cases} s_{1i} = F(\text{Avgpool}(y^j)) = F\left(\frac{1}{1 \times C} \sum_{i=1}^C y_j(i)\right) \\ s_{2i} = F(\text{Maxpool}(y^j)) = F\left(\frac{1}{1 \times C} \sum_{i=1}^C y_j(i)\right) \end{cases} \quad (4)$$

该操作通过卷积函数 $F(\cdot)$ 聚合输入 \mathbf{Y} 中所有跨通道特征,并分别将全局通道信息嵌入到 s_1, s_2 中。然后,将合并之后的全局通道信息 $\mathbf{s} = [s_1, s_2]$ 输入Sigmoid函数得到信号段权重向量,即 $\mathbf{s}' = \sigma(\mathbf{s})$, $\mathbf{s}' \in R^{1 \times w}$ 。 s'_j 表示第*j*个信号段的重要性。信号段重校准向量 \mathbf{s}' 用于重新校准特征 \mathbf{Y} 为:

$$\mathbf{N} = \mathbf{Y} \cdot \mathbf{s}' \quad (5)$$

1.3 CAM

CAM是FAM和SAM的结合,可对输入 \mathbf{Y} 的通道特征和信号段特征赋予不同权重。CAM的基本结构如图1所示。输入特征 \mathbf{Y} 由FAM和SAM从不同角度依次自适应优化。因此,JAM的输出表示为:

$$\mathbf{Y}_{\text{CAM}} = F_{\text{SAM}}(F_{\text{FAM}}(\mathbf{Y})) \quad (6)$$

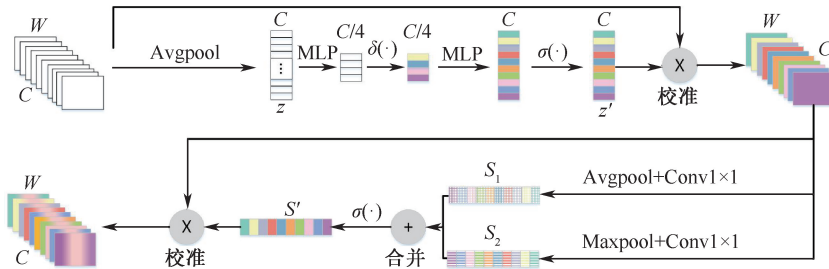


图1 CAM结构

Fig.1 Structure of CAM

CAM通过2级之间的紧密级联使得注意力逐级深入,当输入特征 \mathbf{Y} 的位置(*i, j*)从通道重校准和信号段重校准中获得高度重要性时,被赋予更高的激活性。这种重新校准聚焦于诊断任务中关键的信息,最终实现脉冲信号段的精确定位,从而更准确地故障诊断。

1.4 CLDN网络构建

CAM可简单集成到1D-DenseNet中,以提高特征学习能力。基于提出的CAM,提出CLDN用于变载齿轮箱故障诊断。诊断的整体框架如图2所示。其中,CLDN由1个骨干网络(1D-DenseNet),多个CAM和故障分类层组成。CAM嵌入到骨干网络的每个卷积模块后面,以自适应地优化特征。最后,CLDN使用Softmax函数分类,给出最终的诊断结果。假设输入样本有*n*个类别,则类别*k*的输出概

率 Q_k 为:

$$Q_k = \frac{\exp(w_k X_k)}{\sum_{l=1}^n \exp(w_l X_l)}, l = 1, 2, \dots, n \quad (7)$$

式中: w_k 为权重参数; \mathbf{X} 为网络的输入。

2 故障诊断实例

2.1 试验分析

齿轮箱故障模拟实验台结构如图3所示。采用齿轮箱试验数据验证故障特征提取能力。

齿轮箱振动信号的采样频率为12 kHz,故障样本长度为1 024,滑动窗口移动步长为800,批量尺寸为64。获得包含正常、剥落、点蚀、断齿、缺齿5种状态的数据,对应每一种状态分别设置负载为1、5、9 N·m等3种工况,每种工况选取200个样本,最终得到总

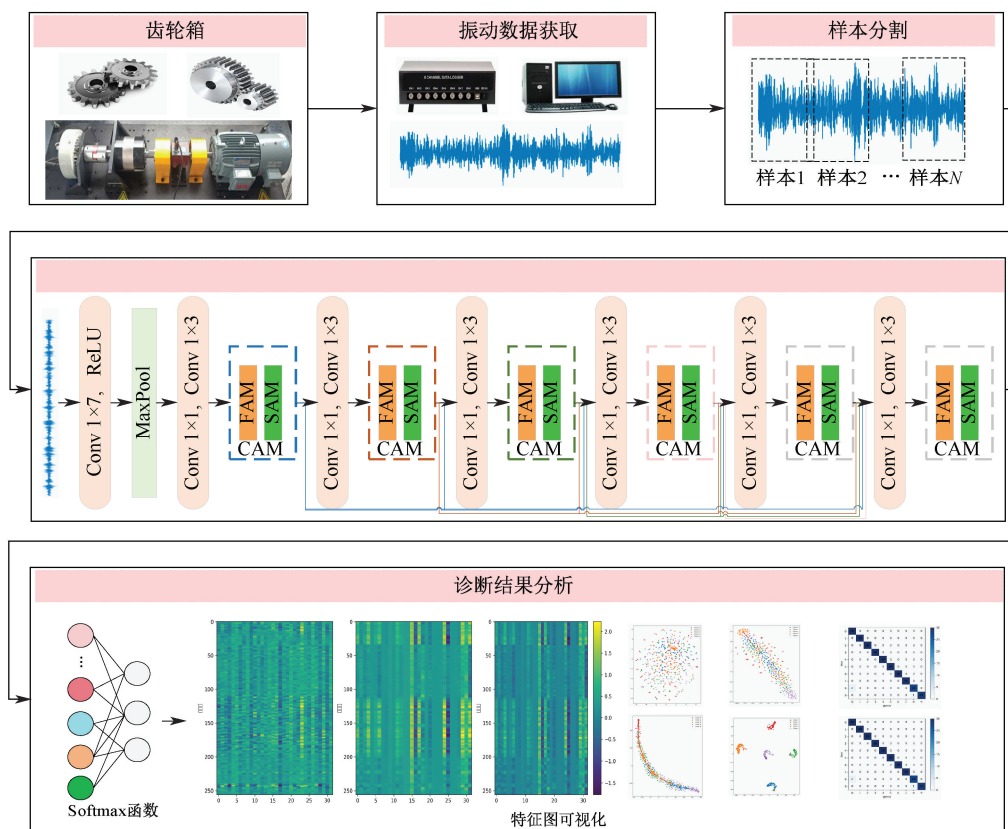


图 2 CLDN 网络结构
Fig. 2 Structure of CLDN



图 3 齿轮箱故障模拟试验台
Fig. 3 Gearbox fault simulation test bench

样本量为 3 000 的数据集,其中,训练集、测试集、验证集的划分比例分别为 70%、15%、15%。

2.2 超参数敏感性分析

不同的超参数,如迭代次数、学习率和批量大小,会对神经网络的准确率和稳定性产生影响。其中,迭代次数和学习率是 2 个关键的超参数^[8]。迭代次数通常需要多次试验来确定;而学习率过大或过小都会影响训练效果。

对迭代次数 e 和学习率 l 这 2 个超参数进行网格搜索,综合之前文献^[9-10],确定搜索空间为: $e \in \{20, 50, 100, 200\}$, $l \in \{0.1, 0.01, 0.001, 0.0001\}$ 。训练环境为 python3.6, TensorFlow2.0, 在各参数组合下得到的分类精度如图 4 所示。结果显示,在大部分参数组合下, e 和 l 对故障诊断结果的影响不大,且 CLDN 方法的最终精度达到 95% 以上,保持在较高水

平,具有较好的故障诊断效果。表明该方法具有较好的超参数稳定性,无需过多的超参数调整即可获得出色的故障诊断效果,具有较好的实际应用潜力。综合考虑故障诊断准确率与计算资源占用率,在后续试验中将 e 和 l 分别设为 50、0.001。




图 4 不同超参数下的分类精度
Fig. 4 Classification accuracy with different hyper-parameters

2.3 CAM 消融试验

为研究 CAM 对特征提取性能的影响,模拟现场

噪声,设计信噪比为-1 dB下的 CAM 消融试验。建立 3 种网络结构:①不使用任何 CAM 的基线网络 DenseNet;②仅使用 FAM 的 DenseNet-FAM 网络;③仅使用 SAM 的 DenseNet-SAM 网络。

试验结果见表 1。针对正常样本,CLDN 的识别

精度达 100%,相较于 DenseNet、DenseNet-FAM 和 DenseNet-SAM,准确率分别提高 7.8、2.2、5.6。表明:CLDN 方法能以较高的精度区分正常样本和其他故障样本,具有良好的实际应用潜力。

对于剥落故障,CLDN方法的诊断精度相对其

表 1 CAM 消融试验

Table 1 Ablation experiments on CAM

%

网络	各类故障状态诊断精度					总体诊断精度
	正常	剥落	点蚀	断齿	缺齿	
DenseNet	92.22	100.00	96.67	88.89	100.00	95.56
DenseNet-FAM	97.78	100.00	96.67	85.56	100.00	96.00
DenseNet-SAM	94.44	100.00	96.67	97.78	100.00	97.78
CLDN	100.00	95.56	100.00	98.89	100.00	98.89

他方法较低。这一现象可能与剥落故障的特性有关。剥落故障通常指的是部件的表面或层次部分脱落,在故障初期,剥落宽度<5 mm 时,通常不会引起明显的信号变化,故障冲击的幅度不明显^[11]。试验中的齿轮箱的剥落宽度为 2 mm,属于故障初期。因此,相较于其他故障,剥落故障可能不存在特定的脉冲特征。而 CAM 更适用于定位信号中的局部、细微的脉冲特征,这在其他类型的故障诊断中可能更为有效。除剥落故障外,CLDN 对其他故障状态的识别精度均优于其他网络,进一步证实了这一点。

为更深入地理解所设计的 CAM 模块的特征提取

机制,针对 CLDN 方法依次对初始特征图、FAM 特征图、SAM 特征图进行可视化,特征图如图 5 所示。图中颜色亮度表示特征重要程度,颜色越亮,特征重要程度越高。在初始特征图中,可以观察到,各通道特征的重要程度基本一致,无法区分重要通道特征和冗余通道特征;FAM 特征图区分了通道的重要性,选择了少数几个重要的通道特征;在此基础上,SAM 进一步选取了重要通道特征中的关键信号段,最终实现了脉冲信号段的精确定位,使得网络的性能有较大提升,诊断精度达到 98.89%。进一步表明所设计的 CAM 模块的有效性以及脉冲特征的重要性。

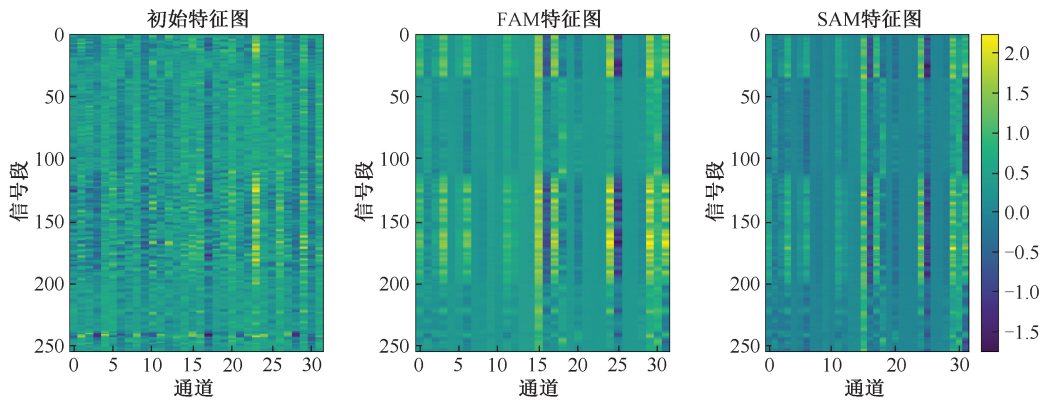


图 5 特征图可视化

Fig. 5 Feature map visualization

2.4 抗噪性分析

对于变载信号,脉冲特征极易被噪声淹没。为研究 CLDN 方法在噪声条件下对脉冲特征的提取能力,分别将 3 种不同强度的高斯白噪声加入原始样本集。并将 CLDN 与 3 种应用广泛的网络(①卷积神经网络(Convolutional Neural Network,CNN);②残差网络 ResNet34;③密集连接网络 DenseNet)以及

4 种常见的注意力机制(①自注意力 Self-Attention;②卷积块注意力模块(Convolutional Block Attention Module,CBAM);③高效通道注意力(Enhanced Convolutional Attention,ECA);④非局部注意力 Non-local)进行比较,其中,4 种注意力机制的基础网络为 DenseNet。结果见表 2。

在 3 种噪声条件下,CLDN 均取得更高的诊断

表 2 抗噪性分析试验

Table 2 Experiment for noise resistance analysis

信噪比/dB	各网络诊断精度								%
	CNN	ResNet34	DenseNet	Self-Attention	CBAM	ECA	No-local	CLDN	
1	89.11	96	97.11	94.89	96.67	98.22	97.78	98.67	
0	87.33	94.89	96.67	92.89	92.44	98	94.22	98.44	
-1	75.78	94.67	95.56	91.11	92.45	96.67	92.89	98.89	
平均值	84.07	95.19	96.45	92.96	93.85	97.63	94.96	98.67	

精度。这表明 CLDN 具有较强的鲁棒稳定性和抗噪性能,能够在噪声干扰下准确提取脉冲特征,从而实现变载齿轮箱更为精确的故障诊断。随着噪声强度的增加,除 CLDN 外的其他诊断方法的识别率都有所下降。但由于噪声鲁棒性不同,这些方法的准确率下降幅度也不同。CNN 受随机噪声影响较为显著,而 CLDN 方法在不同噪声条件下均能保持 98% 以上的准确率,进一步表明 CLDN 具有较好的抗噪能力。将 CLDN 与 Self-Attention、CBAM、ECA、No-local 等 4 种方法对比,在基础网络都为 DenseNet 的情况下,CLDN 相较于其他 4 种注意力机制准确率分别提高 5.7、4.8、1.1、3.7,取得了很高的平均准确率。

为更直观地体现特征提取过程,使用 t-分布邻域嵌入算法将网络中间各层的输出特征进行降维并聚类,可视化效果如图 6 所示。最初原始数据分布杂乱无序,难以区分故障类别,接下来通过逐层的特征提取,到第 2 个密集层后,同类样本逐渐开始聚集;通过第 6 个密集层后,同一故障类别的样本聚集成堆;从最后的全连接层特征可视化图看出,不同故障类型界限清晰,同一类型的故障紧凑地聚集在一起,表明 CLDN 方法在噪声干扰下也具有较好的故障特征提取效果。

2.5 样本不均衡分析

在实际工程中,样本分布通常呈现长尾分布,即正常样本多,故障样本较少,这将导致分类器偏向于多数类样本,从而影响少数类样本(即故障样本)中脉冲特征的提取。因此,设置样本非均衡条件下的故障诊断试验,以进一步验证 CLDN 方法性能。设置故障样本与正常样本的比例为 1:10,数据集的具体设置见表 3。

将 CLDN 方法与各方法对比,结果如图 7 所示。在 5 次相同的重复试验中,CNN 与 ResNet34 的准确率都低于 70%,而以 DenseNet 为基础的其他方法精度都在 80% 以上,更凸显出 DenseNet 网络的优越

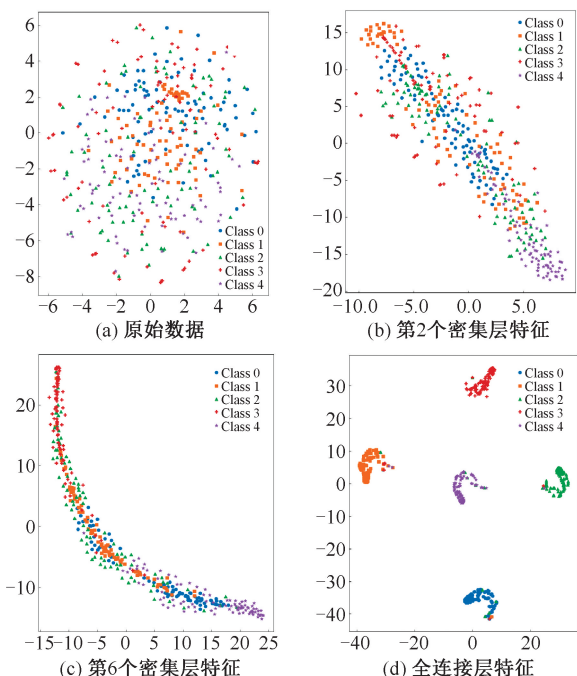


图 6 中间层特征可视化

Fig. 6 Feature visualization of middle layers

表 3 齿轮箱不均衡数据集

Table 3 Unbalance dataset of gearbox

故障类型	负载/(N·m)	训练	验证	测试	故障标签
正常	1	140	30	30	0
	5	140	30	30	
	9	140	30	30	
剥落	1	14	30	30	1
	5	14	30	30	
	9	14	30	30	
点蚀	1	14	30	30	2
	5	14	30	30	
	9	14	30	30	
断齿	1	14	30	30	3
	5	14	30	30	
	9	14	30	30	
缺齿	1	14	30	30	4
	5	14	30	30	
	9	14	30	30	

性。CLDN 在 5 次重复试验中都取得了更好的诊断结果,说明其在样本不均衡的条件下也具有较好的特征提取效果,进一步验证了该方法的性能。




图 7 样本不均衡分析试验

Fig. 7 Experiment for analyzing sample imbalance.

2.6 泛化性分析

为进一步验证 CLDN 方法的泛化性,利用公开的西储大学轴承数据集进行泛化性能试验。试验选用电机驱动端加速度传感器监测的轴承振动信号,轴承设置有内圈故障 (Inner Race Fault, IR)、外圈故障 (Outer Race Fault, OR)、滚动体故障 (Ball Fault, BA) 3 种故障情况。对应每种故障类型的损伤直径分别为 0.18、0.36、0.53 mm,加上正常状态,一共设置 10 种故障类型,见表 4。

表 4 轴承故障数据集

Table 4 Bearing fault dataset

故障类型	负载/kW×转速/ (r·min ⁻¹)	训 练	验 证	测 试	故 障 标 签
正常	2.250×1 730	140	30	30	0
内圈故障 IR1	0×1 797	140	30	30	1
内圈故障 IR2		140	30	30	2
内圈故障 IR3		140	30	30	3
外圈故障 OR1	0.735×1 772	140	30	30	4
外圈故障 OR2		140	30	30	5
外圈故障 OR3		140	30	30	6
滚动体故障 BA1	1.470×1 750	140	30	30	7
滚动体故障 BA2		140	30	30	8
滚动体故障 BA3		140	30	30	9

将 8 种方法在 3 种噪声条件(1、0、-1 dB)下进行对比,结果如图 8 所示。随着噪声强度的增加,各方法的准确率都有所下降,且 CNN 受噪声影响较大,与 2.4 节的试验结果是一致的。在 3 种噪声条件下,CLDN 的精度都优于其他方法,表明在轴承数据集上,该方法也有较好的特征提取能力,具有较强的泛化性能。

为进一步显示 CLDN 方法对各个故障类型的详

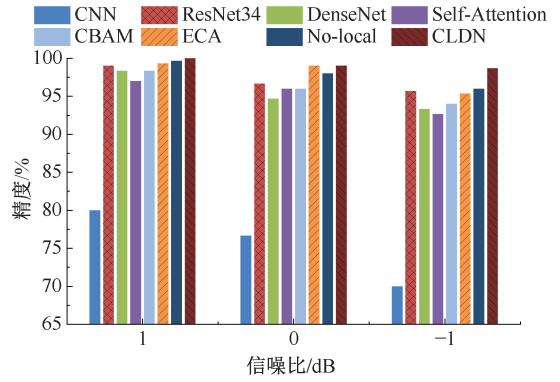


图 8 泛化性分析试验

Fig. 8 Experiment for generalization analysis

细识别效果,得到分类混淆矩阵如图 9 所示。可以看出,真实标签 8 和 9 的样本预测准确率分别为 93%和 97%,其余 8 类的故障诊断准确率均达到 100%,整体的测试集准确率达到 99%,说明 CLDN 在公开的西储大学轴承数据集的故障诊断中表现较好,能够从复杂故障模式中提取到有效的故障特征,实现轴承故障的准确分类,具有较强的鲁棒性和泛化性能。




图 9 分类混淆矩阵

Fig. 9 Classification confusion matrix

3 结 论

1) 设计的 CAM 能够有效提取一维信号的脉冲特征。CAM 相较于 Self-Attention 等 4 种常见的注意力机制准确率平均提升 3.8%,可实现脉冲特征的准确定位。

2) CLDN 方法能够自适应地重新校准每一层的特征,从而增强脉冲信号的特征学习。CLDN 相较于 ResNet34 等 7 种诊断方法准确率提升 3.7%~14.6%,具有更好的特征提取效果。

3) 提出的 CAM 可以集成到现有的神经网络架构中,改善网络的特征提取能力,以提高其诊断性能。

参 考 文 献

- [1] KUMAR S, KUMAR V, SARANGI S, et al. Gearbox fault diagnosis: a higher order moments approach [J]. *Measurement*, 2023, 210: DOI: 10.1016/j.measurement.2023.112489.
- [2] HUSSAIN S, GABBAR H. A novel method for real time gear fault detection based on pulse shape analysis [J]. *Mechanical Systems and Signal Processing*, 2011, 25(4): 1 287-1 298.
- [3] LI Jimeng, YAO Xifeng, WANG Xiangdong, et al. Multiscale local features learning based on BP neural network for rolling bearing intelligent fault diagnosis [J]. *Measurement*, 2020, 153: DOI: 10.1016/j.measurement.2019.107419.
- [4] 张斌,张辛忻,杨海涛. 基于神经网络的振动给料机故障诊断算法 [J]. *中国安全科学学报*, 2023, 33(增 2): 55-59.
ZHANG Bin, ZHANG Xinxin, YANG Haitao. Neural network-based fault diagnosis algorithm for vibration feeder [J]. *China Safety Science Journal*, 2023, 33(S2): 55-59.
- [5] 王庆荣,王媛,朱昌锋,等. 双通道交叉密集连接的滚动轴承故障诊断 [J/OL]. *机械科学与技术*: 1-9 [2023-04-06]. <https://doi.org/10.13433/j.cnki.1003-8728.20230188>.
WANG Qingrong, WANG Yuan, ZHU Changfeng, et al. Fault diagnosis of rolling bearings with two-channel cross-dense connection [J]. *Mechanical Science and Technology for Aerospace Engineering*: 1-9 [2023-04-06]. <https://doi.org/10.13433/j.cnki.1003-8728.20230188>.
- [6] WOO S, PARK J, LEE J, et al. CBAM: convolutional block attention module [C]. *Proceedings of the 15th European Conference on Computer Vision (ECCV)*, 2018: 3-19.
- [7] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7 132-7 141.
- [8] TANG Shenggan, ZHU Yong, YUAN Shouqi. Intelligent fault diagnosis of hydraulic piston pump based on deep learning and Bayesian optimization [J]. *ISA Transactions*, 2022, 129: 555-563.
- [9] ZHAO Xiaoli, YAO Jianyong, DENG Wenxiang, et al. Multiscale deep graph convolutional networks for intelligent fault diagnosis of rotor-bearing system under fluctuating working conditions [J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(1): 166-176.
- [10] 王金江,关鹏婷,陈卓,等. 基于深度学习的检修作业过程风险智能预警 [J]. *中国安全科学学报*, 2023, 33(10): 16-22.
WANG Jinjiang, GUAN Pengting, CHEN Zhuo, et al. Intelligent warning of risk during maintenance operations based on deep learning [J]. *China Safety Science Journal*, 2023, 33(10): 16-22.
- [11] MENG Zong, SHI Guixia, WANG Fulin. Vibration response and fault characteristics analysis of gear based on time-varying mesh stiffness [J]. *Mechanism and Machine Theory*, 2020, 148: DOI: 10.1016/j.mechmachtheory.2020.103786.



作者简介: 樊晓萱 (2000—),女,湖南益阳人,博士研究生,研究方向为安全大数据与人工智能。E-mail:2018010731@student.cup.edu.cn。