

多模态残差注意力网络异步电动机故障诊断*

古玉锋, 燕钢强, 黎程山, 苟瑞龙

(长安大学道路施工技术与装备教育部重点实验室 西安, 710064)

摘要 针对在线故障诊断中多源信息利用不足与模型识别精度不高的问题,提出了一种主成分分析(principal component analysis, 简称PCA)与残差注意力网络相结合的多传感器融合故障诊断方法(multi-sensor feature fusion residual attention network, 简称MSF-ResAttNet),以实现三相异步交流电动机的高精度诊断。首先,采集电动机在不同运行状态下的振动、电压及电流等多源信号;其次,利用PCA对同源传感器数据进行数据层融合,增强多源信息的关联性与稳定性;然后,将数据层融合后的特征输入结合多分支残差结构与通道-空间双重注意力机制(convolutional block attention module, 简称CBAM)注意力模块的深度神经网络,实现对关键特征通道和空间位置的自适应提取与强化;最后,在电动机故障诊断实验平台上与卷积神经网络(convolutional neural network, 简称CNN)、残差神经网络(residual neural network, 简称ResNet)、早期融合卷积神经网络(early fusion convolutional neural network, 简称EF-CNN)及多传感器融合卷积神经网络(multi-sensor feature fusion convolutional neural network, 简称MSF-CNN)进行对比,并在公开数据集KAIST上进行迁移测试。结果表明,MSF-ResAttNet在实验平台的诊断准确率为99.57%,在公开数据集KAIST测试的诊断准确率为98.86%,与其他方法相比均具有一定的优势,提升了电动机故障诊断的精度,具有较强的泛化能力。

关键词 多传感器融合;异步电动机;故障诊断;残差神经网络;注意力机制
中图分类号 TM307;TH17

引言

三相异步交流电动机常出现转子断条、定子绕组短路、轴承内外圈损伤及滚动体失效等故障。因此,电机故障诊断一直是研究的热点问题。传统故障诊断方法^[1]采用单一传感器信号的阈值判断与频谱分析,难以应对多故障耦合场景,且易受环境噪声干扰,误诊率高^[2]。以CNN^[3]为代表的深度学习故障诊断方法从原始信号中自动挖掘隐藏特征,降低了对先验知识的依赖,已成为故障诊断的主流方法。Jigyasu等^[4]提出了一种融合时频分析和深度迁移学习的电动机故障诊断方法,通过时频表征与迁移学习的协同优化,对电动机进行故障诊断。Jia等^[5]提出了一种具有并行卷积核和通道注意力机制模块的深度注意力卷积神经网络模型,进行变负荷和高噪声环境下电动机轴承故障诊断。多传感器信息融合^[6]利用不同传感器的信息特征,可实现电动机运行状态的特征互补,其融合策略主要分为数据级^[7]、特征级^[8]与决策级^[9]3类。Shu等^[10]通过相关峭度规则对多传感器信号进行加权融合,并结合特征融合网络进行跨维度信息整合,实

现对滚动轴承的故障诊断。马明晗等^[11]提出了基于多尺度核卷积神经网络和多源机电信息融合的电机故障诊断方法,通过多尺度核算法并行提取互补特征并融合相电压、转子振动与定子振动等多源信号,实现了端到端的故障分类。赵耀等^[12]提出了基于决策级融合的电动机双凸极电动机短路的故障诊断方法,通过自寻优CNN与支持向量机分别提取振动和相电流信号的单源诊断概率,并基于D-S证据理论实现了多源信号的决策级融合。

现场的复杂工况可能导致原始数据信噪比下降,传统融合模型因缺乏动态噪声抑制机制而鲁棒性不足。振动、电流等传感器信号在时频特性、噪声分布及物理量纲方面差异显著,异构信号的直接融合可能引发信息冗余或特征失真。针对上述问题,笔者提出一种基于PCA和残差注意力网络的多传感器融合故障诊断方法,面向三相异步交流电动机的多种典型故障构建诊断模型,整合振动、电压、电流和温度信号,构建数据层-特征层双阶段融合策略,引入CBAM以提高故障诊断的准确率,并通过实验验证所提出方法的有效性。

* 国家自然科学基金资助项目(52205249)

收稿日期:2025-06-11;修回日期:2025-08-18

1 MSF-ResAttNet 基础模块

1.1 主成分分析

主成分分析是一种经典的数据降维方法,通过数学变换将多维信号投影至低维正交主元空间,既保留了核心故障特征,也实现了数据提纯^[13]。

设 m 个同类传感器在时间 T 内采集到 n 个数据点,构成原始样本矩阵,即

$$X = \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1m} \\ X_{21} & X_{22} & \cdots & X_{2m} \\ \vdots & \vdots & & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{nm} \end{bmatrix} = [X_1, X_2, \cdots, X_m] \quad (1)$$

其中: X_{ij} 为第 j 个传感器采集的第 i 个数据点。

对每个传感器信号进行 Z-score 标准化,得到标准化矩阵中的各个元素为

$$Y_{ij} = \frac{X_{ij} - \mu_j}{\sigma_j} \quad (i = 1, 2, \cdots, n; j = 1, 2, \cdots, m) \quad (2)$$

其中: μ_j 和 σ_j 分别为第 j 个传感器的均值和标准差。

标准化后的矩阵为

$$Y = \begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1m} \\ Y_{21} & Y_{22} & \cdots & Y_{2m} \\ \vdots & \vdots & & \vdots \\ Y_{n1} & Y_{n2} & \cdots & Y_{nm} \end{bmatrix} = [Y_1, Y_2, \cdots, Y_m] \quad (3)$$

标准化数据的协方差矩阵为

$$C = \frac{1}{n-1} Y^T Y = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1m} \\ c_{21} & c_{22} & \cdots & c_{2m} \\ \vdots & \vdots & & \vdots \\ c_{m1} & c_{m2} & \cdots & c_{mm} \end{bmatrix} \quad (4)$$

其中: $c_{jk} = \frac{1}{n-1} \sum_{i=1}^n Y_{ij} Y_{ik}$

对协方差矩阵 C 进行特征值分解,即

$$C = V \Lambda V^T \quad (5)$$

得到正交特征向量矩阵 $V = [v_1, v_2, \cdots, v_m]$, 选择前 k 个主成分构成投影矩阵 $V_k = [v_1, v_2, \cdots, v_k]$ 。

将标准化数据投影到主成分方向,生成融合后的信号为

$S =$

$$\begin{bmatrix} \sum_{j=1}^m Y_{1j} v_{j1} & \sum_{j=1}^m Y_{1j} v_{j2} & \cdots & \sum_{j=1}^m Y_{1j} v_{jk} \\ \sum_{j=1}^m Y_{2j} v_{j1} & \sum_{j=1}^m Y_{2j} v_{j2} & \cdots & \sum_{j=1}^m Y_{2j} v_{jk} \\ \vdots & \vdots & & \vdots \\ \sum_{j=1}^m Y_{nj} v_{j1} & \sum_{j=1}^m Y_{nj} v_{j2} & \cdots & \sum_{j=1}^m Y_{nj} v_{jk} \end{bmatrix} \quad (6)$$

若仅保留第 1 主成分 ($k=1$), 则融合信号简化为

$$S_i = \sum_{j=1}^m \omega_j Y_{ij} \quad (i = 1, 2, \cdots, n) \quad (7)$$

其中: 权重 $\omega_j = v_{j1}$, 即为第 1 主成分的特征向量。

1.2 残差神经网络

ResNet 通过跨层跳跃连接构造残差映射函数^[14], 提高了超深层神经网络的优化能力。残差块结构如图 1 所示。




图 1 残差块结构图

Fig.1 Diagram of residual block structure

假设期望的底层映射为 $H(x)$, 则网络实际学习的目标为

$$H(x) = F(x, W_i) + W_m * x \quad (i = 1, 2) \quad (8)$$

其中: x 为输入特征; $F(x, W_i)$ 为残差函数, 表示为 $W_2 * \sigma(W_1 * x)$; W_1 和 W_2 分别为 2 个连续堆叠的 3×3 卷积层的权重矩阵; σ 为 ReLU 函数; W_m 为权重矩阵。

为实现输入特征与输出特征的维度匹配, 引入可调整的 1×1 卷积层, 当输入特征与输出特征的维度相同时, W_m 退化为单位矩阵, 此时卷积层执行恒等映射。

1.3 通道-空间双重注意力机制

CBAM 构建了级联式双注意力机制^[15], 形成了“通道-空间”双域协同的特征选择机制, 有效抑制了背景噪声干扰, 增强了模型对判别性特征的捕获能力。图 2 为 CBAM 模块结构图。

假设给定输入特征图 F , 其优化过程分解为

$$F' = M_c(F) \otimes F \quad (9)$$

$$F'' = M_s(F') \otimes F' \quad (10)$$

其中: $M_c()$ 和 $M_s()$ 分别为通道和空间注意力映射函数; $\otimes$ 表示逐元素乘法操作。

通道注意力模块采用全局平均池化与最大池化




图2 CBAM模块结构图

Fig.2 Diagram of CBAM module structure

的双路聚合策略,通过共享参数的多层感知机 (multi-layer perceptron, 简称 MLP) 生成通道权重,即

$$M_c(F) = \sigma'(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \quad (11)$$

空间注意力模块通过通道维度的池化压缩与 7×7 卷积生成空间掩码,即

$$M_s(F') = \sigma'(f^{7 \times 7}([\text{AvgPool}_c(F'); \text{MaxPool}_c(F')])) \quad (12)$$

其中: σ' 为 Sigmoid 激活函数; $f^{7 \times 7}$ 为 7×7 卷积核。

2 基于MSF-ResAttNet的多传感器融合电动机故障诊断

2.1 电动机多传感器故障信息融合框架

图3为电动机多传感器信息融合框架,其主要由2部分组成:多源同类信息数据层融合和多源异类信息特征层融合。




图3 电动机多传感器信息融合框架

Fig.3 Multi-sensor information fusion framework for motor

2.2 基于主成分分析的多源同类信息数据层融合

2.2.1 电动机的多源故障信息

利用传感器分别采集电动机的振动、电压、电流及温度信号,得到电动机的多源同类信息和多源异类

信息分别如表1、2所示。多源同类信息为同类型传感器组采集的多个信号,同类信息经数据融合处理并增加后轴承振动与定子铁心温度组成多源异类信息。

2.2.2 主成分分析融合

采用主成分分析对多源同类信息进行数据层融

合,图 4 为多源同类信息数据层融合流程图。

表 1 电动机的多源同类信息
Tab.1 multi-source homogeneous information of motor

同类传感器信息	信号	单位
多源同类信息 1	前轴承水平方向振动 V_H	m/s
	前轴承垂直方向振动 V_V	m/s
多源同类信息 2	电动机 A 相电压 U_A	V
	电动机 B 相电压 U_B	V
	电动机 C 相电压 U_C	V
多源同类信息 3	定子 A 相电流 I_A	A
	定子 B 相电流 I_B	A
	定子 C 相电流 I_C	A
多源同类信息 4	电动机 A 相绕组温度 T_A	°C
	电动机 B 相绕组温度 T_B	°C
	电动机 C 相绕组温度 T_C	°C

表 2 电动机的多源异类信息
Tab.2 multi-source heterogeneous information of motor

异类传感器信息	信号	单位
多源异类信息 1	综合前轴承振动 V_E	m/s
多源异类信息 2	后轴承振动 V_A	m/s
多源异类信息 3	综合电动机电压 U_E	V
多源异类信息 4	综合电动机电流 I_E	A
多源异类信息 5	综合电动机绕组温度 T_E	°C
多源异类信息 6	定子铁心温度 T_F	°C




图 4 多源同类信息数据层融合流程图
Fig.4 Flowchart of multi-source homogeneous data-level fusion

针对所采集的同类传感器数据,计算了主成分的方差贡献率。分析发现,第 1 主成分的方差贡献率均超过 91.3%,选择 $k=1$ 能够充分表征原始多传感器数据的核心变化信息,为复杂工况的精准故障诊断提供了高信噪比输入。

2.3 基于 ResAttNet 的多源异类信息特征层融合

特征融合采用多分支协同设计。由于振动信号具有明显的时频特性,通常需要转换为时频图像进行二维空间特征提取,因此采用二维残差网络。由

于电压、电流等电气信号以及温度信号本质上是时间序列,其频域和时序特征更适合一维卷积操作,因此采用一维残差网络。图 5 为多源异类信息特征层融合流程图。




图 5 多源异类信息特征层融合流程图
Fig.5 Flowchart of multi-source heterogeneous feature-level fusion

各分支特征经空间维度统一化处理后,在 16×16 的特征网格进行通道拼接融合,通过 CBAM 进行通道-空间双维度特征增强。该融合策略在保留异构信号时空特性的同时,通过残差连接的多级精炼实现了跨模态特征的深度交互。

2.4 故障诊断流程

笔者提出的故障诊断流程如图 6 所示,分为数据采集、数据处理、模型训练及实验验证 4 个部分。

1) 数据采集。在三相异步交流电动机关键点部署振动传感器组、电压与电流传感器组及分布式温度传感器组,采集多源同类信号。

2) 数据处理。对采集到的数据进行切片、标




图 6 电动机故障诊断流程

Fig.6 Flow chart of motor fault diagnosis

准化等预处理,进行数据层融合,将处理好的数据按照 7:2:1 的比例划分为训练集、验证集和测试集。

3) 模型训练。将训练数据输入 MSF-ResAttNet 诊断模型进行初始训练,利用验证集动态监测模型的诊断性能。采用误差反向传播算法持续调整网络参数,保存全局最优模型。

4) 实验验证。将测试集输入训练后的故障诊断模型进行特征提取与融合,输出故障诊断结果。

3 实验验证与结果分析

3.1 数据采集

本实验采用的三相异步交流电动机数据采集实验台如图 7 所示。实验台配备了可替换的故障电机及轴承组件,通过变频器实现电机调速,并利用涡流制动器模拟负载变化,输出扭矩由动态扭矩传感器在线监测。振动传感器分别放置在前轴承座正交方向及后轴承垂直方向;电压与电流传感器放置在变频器的输出端;接触式温度传感器监测定子铁芯及绕组的温度升高。




图 7 数据采集实验台

Fig.7 Data acquisition experimental platform

在实验台上分别模拟电动机的 7 种典型故障:电动机正常、定子匝间短路、转子断条、轴承外圈故障、轴承内圈故障、轴承滚动体故障和轴承联合故障。实验运行参数如表 3 所示。振动信号、电压信号、电流信号及温度信号的采样频率均为 5 kHz,采样时间为 120 s,每种故障状态采集 6×10^5 个数据。

表 3 实验运行参数	
Tab.3 Experimental operating parameters	
参数	数值
电动机电流/A	2.49
电动机电压/V	380
电动机转速/(r·min ⁻¹)	2 840
模拟扭矩/(N·m)	3.70
控制器输出电流/A	0.18

3.2 数据预处理

为了提高神经网络特征的提取效率,将每种故障状态下的原始数据经非重叠窗口划分为 1 000 个样本,每个样本包含 600 个数据点,并对多源同类信息融合处理。按照机器学习的常规数据分配原则划分数据并设置相应的标签,各故障状态的数据集标签与数量如表 4 所示。

表 4 数据集标签与数量			
Tab.4 Label and number of datasets			
电动机故障状态	故障类别标签	样本数量(训练集/验证集/测试集)	样本长度
正常状态	1	700/200/100	600
定子匝间短路	2	700/200/100	600
转子断条	3	700/200/100	600
轴承外圈故障	4	700/200/100	600
轴承内圈故障	5	700/200/100	600
轴承滚动体故障	6	700/200/100	600
轴承联合故障	7	700/200/100	600

3.3 模型训练

笔者构建的 MSF-ResAttNet 模型以预处理后融合的振动、电压、电流及温度信号作为输入,通过多尺度特征提取与注意力机制并行的残差模块生成多组特征映射,所有隐藏层统一采用 ReLU 函数激活以加速收敛并防止梯度消失,在全连接层引入随

机失活(Dropout)以抑制过拟合,输出端通过 Softmax 函数对各故障类别概率进行归一化,并以概率最高者作为诊断结果。在训练过程中,模型以交叉熵损失函数为优化目标,采用 AdamW 优化网络参数,训练批次为 64,训练 80 个轮次,每进行一个小批量训练即更新一次网络参数,并在验证集准确率提升时保存最优模型。模型参数如表 5 所示。

表 5 模型参数
Tab.5 Model parameters

模块	结构名称	结构参数	输出形状	备注
振动分支	二维卷积层	维度 2→64,7×7	64×64×1×99	初始特征提取
	池化层	k(1×3)	64×64×1×50	时域降采样
	二维残差块×4	维度 64→128→256→512,3×3	64×512×1×16	深层残差特征
	自适应平均池化层	输出(4×25)	64×512×4×25	全局空间池化
电气分支	一维卷积层	维度 2→64,15	64×64×100	初始编码
	一维残差块×3	维度 64→128→256→512	64×512×25	深层残差特征
	自适应平均池化层	输出(25)	64×512×25	全局长度池化
温度分支	一维卷积层	维度 2→64,15	64×64×100	初始编码
	一维残差块×3	维度 64→128→256→512	64×512×25	深层残差特征
特征融合	二维卷积层	维度 512→512,3×3	64×512×4×25	振动特征对齐
	一维卷积层	维度 512→512,3	64×512×4×25	电气特征对齐
	一维卷积层	维度 512→512,3	64×512×4×25	温度特征对齐
	拼接层	—	64×1536×4×25	通道级拼接
CBAM	通道注意力模块	1×1 卷积	64×1536×4×25	通道注意力
	空间注意力模块	7×7 卷积	64×1536×4×25	空间注意力
分类头	二维残差块×2	维度 1 536→1 024→512	64×512×4×25	精炼特征
	自适应平均池化层	输出(1×1)	64×512×1×1	全局池化
	展平层	—	64×512	向量化
	全连接层(BN+ReLU)	维度 512→256	64×256	非线性特征变换
	全连接层	维度 256→7	64×7	最终分类输出

选取准确率、精确率及召回率 3 项指标评估神经网络训练模型的性能。准确率的计算公式为

$$\text{Accuracy} = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (13)$$

其中: T_p 和 T_N 分别表示被正确预测为故障和正常的样本数; F_p 和 F_N 分别表示被误判为故障和被漏判为故障的样本数。

精确率的定义为

$$\text{Precision} = \frac{T_p}{T_p + F_p} \quad (14)$$

召回率的定义为

$$\text{Recall} = \frac{T_p}{T_p + F_N} \quad (15)$$

图 8 为故障诊断模型在 80 次迭代过程中的

训练/验证准确率和损失值的变化曲线。在前 20 次迭代,训练准确率从 50% 上升至 98% 以上,训练损失由 1.07 迅速下降至 0.10 以下;验证准确率和验证损失呈现相似趋势,但由于训练集与测试集分布存在差异,验证准确率在此阶段出现了较明显的上下波动。迭代 40 次以后,训练与验证曲线开始趋于平稳,训练准确率和验证准确率双双逼近 100%,且验证准确率的波动幅度明显减小,训练损失逐渐趋近于 0。当迭代次数达到 70 次及以上时,验证准确率维持稳定在 99% 以上,训练损失收敛至最小值,表明模型已充分拟合训练数据,且在测试集上具有良好的泛化性能。




图 8 模型准确率和损失值的变化曲线
Fig.8 Curves of model accuracy and loss value

3.4 实验结果与分析

3.4.1 整体性能分析

为了系统验证 MSF-ResAttNet 模型在多模态信号融合条件下的故障诊断性能,与 4 种诊断方法

(CNN、ResNet、EF-CNN 及 MSF-CNN) 进行实验对比。不同网络模型准确率对比如表 6 所示。CNN 与 ResNet 均采用两路振动信号输入,分别体现基础网络与深层结构的差异。EF-CNN 将两路振动、综合电压、综合电流及两路温度直接在输入层进行通道拼接,通过统一的卷积网络提取特征。MSF-CNN 和 MSF-ResAttNet 采用多分支结构,分别处理不同模态的输入,并在高层进行特征融合,MSF-ResAttNet 进一步引入了注意力机制以增强关键模态特征的表达能力。

实验结果表明,随着输入模态种类的增加与融合策略的优化,模型诊断性能显著提升。基础的 CNN 方法和 ResNet 方法在处理单一模态信号时准确率仅为 88.56% 和 91.21%,而融合多模态信息的 EF-CNN 和 MSF-CNN 准确率分别达到 96.83% 和 96.46%。MSF-ResAttNet 凭借其多分支结构与注意力机制,融合振动、电压、电流及温度信号后,诊断准确率达到 99.57%,优于其他模型,也验证了 MSF-ResAttNet 在多元信息融合故障诊断中的有效性。

表 6 不同网络模型准确率对比

Tab.6 Accuracy comparison of different network models				
序号	诊断方法	模态类型	融合策略	准确率/%
1	CNN	两路振动	单模态	88.56
2	ResNet	两路振动	单模态	91.21
3	EF-CNN	振动+电压+电流+温度	早期融合	96.83
4	MSF-CNN	振动+电压+电流+温度	多分支融合	96.46
5	MSF-ResAttNet	振动+电压+电流+温度	多分支+注意力融合	99.57

图 9 为模型对测试集故障诊断所得的混淆矩阵。最右侧数字对应各故障类别的召回率,最底部一行对应各故障类别的精确率,右下角的单元格为诊断的准确率。由混淆矩阵可知,故障 2、3、4 各有 1 个样本被误分到其他类别,其余故障类别分类正确,准确率为 99.57%。

对模型输出的数据进行 t-SNE 降维处理,并将不同类别的样本以不同颜色的点进行标注,得到 t-SNE 可视化散点图如图 10 所示。相同类别的点互相聚合,不同类别的点相距较远,具有明显的界限,只有极少数点分类错误,进一步验证了本研究方法在故障诊断方面的性能。

3.4.2 消融实验

为了验证笔者所提方法中各关键模块的有效性,设计了模块消融实验,以评估 PCA 和 CBAM 对模型性能的贡献。具体消融方式如下:①模型 A:移除 PCA 数据层融合和 CBAM 注意力模块的基准模




图 9 混淆矩阵

Fig.9 Confusion matrix

型;②模型 B:在模型 A 基础上加入 PCA 数据层融合;③模型 C:在模型 A 基础上加入 CBAM 注意力模块;④模型 D:完整模型(MSF-ResAttNet)。




图 10 t-SNE 可视化散点图

Fig.10 t-SNE visualization scatter plot

表 7 为消融实验结果对比。可以看出,PCA 和 CBAM 模块均有效提升了诊断性能,完整模型的诊断准确率优于其他消融模型,验证了各模块提升故障识别效果的有效性。

表 7 消融实验结果对比

Tab.7 Comparison of ablation experiment results			
模型	PCA	CBAM	准确率/%
A	无	无	95.83
B	有	无	98.04
C	无	有	97.98
D	有	有	99.57

3.4.3 公开数据集验证

为了验证模型的泛化能力,在 KAIST 公开数据集^[16]上进行了迁移测试。先对数据集进行预处理,使用与笔者提出模型结构兼容的传感器通道进行特征提取,并保留原有训练策略,再与 CNN、ResNet、EF-CNN 及 MSF-CNN 方法进行比较。KAIST 公开数据集中不同网络模型准确率对比如表 8 所示。

表 8 KAIST 公开数据集中不同网络模型准确率对比

Tab.8 Comparison of accuracy of different network models on KAIST public dataset		
诊断方法	模态类型	准确率/%
CNN	两路振动	91.43
ResNet	两路振动	90.14
EF-CNN	振动+电流+温度	94.86
MSF-CNN	振动+电流+温度	95.71
MSF-ResAttNet	振动+电流+温度	98.86

结果表明,MSF-ResAttNet 在该公开数据集上的诊断准确率达到 98.86%,优于其他 4 种方法,表现出模型较强的泛化能力。

4 结 论

1) 基于 PCA 的数据层融合策略,整合了多源

传感器数据的互补信息,减少了单一传感器信息不全所引起的误诊。

2) 引入融合 CBAM 模块的多分支残差神经网络,实现了关键通道与空间特征的精细建模及自适应增强,提高了深层特征的表达能力。

3) 在电动机故障诊断实验台上,MSF-ResAttNet 模型表现出了良好的性能,诊断准确率达 99.57%,与 CNN、ResNet、EF-CNN 及 MSF-CNN 模型对比,准确率分别提高了 11.01%、8.36%、2.74% 及 3.11%,验证了多层次融合策略的有效性。

4) 在 KAIST 公开数据集上,MSF-ResAttNet 模型同样取得了 98.86% 的诊断准确率,优于 CNN、ResNet、EF-CNN 及 MSF-CNN 模型,验证了所提出方法的泛化能力。

5) MSF-ResAttNet 模型不仅提高了电动机故障诊断的准确率,还为多源信息融合在工业智能运维中的应用提供了可行思路。

参 考 文 献

[1] 李彦夫, 韩特. 基于深度学习的工业装备 PHM 研究综述[J]. 振动、测试与诊断, 2022, 42(5): 835-847.
LI Yanfu, HAN Te. Review on deep learning based PHM for industrial equipment[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(5): 835-847. (in Chinese)

[2] JUNIOR R F R, AREIAS I A D S, CAMPOS M M, et al. Fault detection and diagnosis in electric motors using 1d convolutional neural networks with multi-channel vibration signals[J]. Measurement, 2022, 190: 110759.


[3] 邢自扬, 赵荣珍, 吴耀春, 等. 多尺度卷积神经网络小样本轴承故障辨识方法[J]. 振动、测试与诊断, 2023, 43(5): 915-922.
XING Ziyang, ZHAO Rongzhen, WU Yaochun, et al. Multi-scale convolutional neural network small sample bearing fault identification method[J]. Journal of Vibration, Measurement & Diagnosis, 2023, 43(5): 915-922. (in Chinese)

[4] JIGYASU R, SHRIVASTAVA V, SINGH S. Advance deep convolution neural network for multiple fault diagnosis of induction motor[C]//2022 IEEE 10th Power India International Conference (PIICON). New Delhi, India: IEEE, 2022: 1-6.

[5] JIA Z Z, LIU J X, GAO J, et al. Research on fault diagnosis method of induction motor bearing based on DACNN[C]//The Second International Conference on Cyber-Energy Systems and Intelligent Energy. Shenyang, China: IEEE, 2024: 1-6.

[6] 何友, 刘瑜, 李耀文, 等. 多源信息融合发展及展望[J]. 航空学报, 2025, 46(6): 1-26.
HE You, LIU Yu, LI Yaowen, et al. Development

- and prospects of multisource information fusion[J]. *Acta Aeronautica et Astronautica Sinica*, 2025, 46(6): 1-26. (in Chinese)
- [7] XIE T L, HUANG X F, CHOI S K. Intelligent mechanical fault diagnosis using multi-sensor fusion and convolution neural network[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(5): 3213-3223.
- [8] 苏宇, 温广瑞, 徐斌, 等. 基于 Kernel-MCCA 特征融合的齿轮故障诊断方法[J]. *振动、测试与诊断*, 2022, 42(3): 511-517.
SU Yu, WEN Guangrui, XU Bin, et al. Gear fault diagnosis method based on Kernel-MCCA feature fusion[J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(3): 511-517. (in Chinese)
- [9] HUO Z Q, MARTÍNEZ-GARCÍA M, ZHANG Y, et al. A multi-sensor information fusion method for high-reliability fault diagnosis of rotating machinery[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 71: 1-12.
- [10] SHU Y D, MA T C, LIN Y G. Rolling bearing fault diagnosis based on data-level and feature-level information fusion[J]. *Journal of Southeast University (English Edition)*, 2024, 40(4): 396.
- [11] 马明晗, 侯岳佳, 李永刚, 等. 基于 MSK-CNN 和多源机电信息融合的同步发电机故障诊断方法[J]. *电机与控制学报*, 2023, 27(1): 1-11.
MA Minghan, HOU Yuejia, LI Yonggang, et al. Synchronous generator fault diagnosis method based on MSK-CNN and multi-source electromechanical information fusion[J]. *Electric Machines and Control*, 2023, 27(1): 1-11. (in Chinese)
- [12] 赵耀, 陆佳煜, 李东东, 等. 基于机电信号融合的电励磁双凸极电机绕组匝间短路故障诊断[J]. *电工技术学报*, 2023, 38(1): 204-219.
ZHAO Yao, LU Jiayu, LI Dongdong, et al. A fault diagnosis strategy for winding inter-turn short-circuit fault in doubly salient electro-magnetic machine based on mechanical and electrical signal fusion[J]. *Transactions of China Electrotechnical Society*, 2023, 38(1): 204-219. (in Chinese)
- [13] 付骏宇, 许景辉. 基于双通道数据主振动特征提取的水电机组轴系故障诊断[J]. *噪声与振动控制*, 2024, 44(5): 172-178.
FU Junyu, XU Jinghui. Fault diagnosis based on primary vibration feature extraction of dual-channel data for shaft systems of hydropower units[J]. *Noise and Vibration Control*, 2024, 44(5): 172-178. (in Chinese)
- [14] ZHANG X C, PAN X, ZENG H, et al. Intelligent diagnosis method for typical co-frequency vibration faults of rotating machinery based on SAE and ensembled ResNet-SVM[J]. *Chinese Journal of Mechanical Engineering*, 2024, 37(1): 64.
- [15] XU S J, YUAN R, LÜ Y, et al. A novel fault diagnosis approach of rolling bearing using intrinsic feature extraction and CBAM-enhanced Inception Net[J]. *Measurement Science and Technology*, 2023, 34(10): 105111.
- [16] JUNG W, KIM S H, YUN S H, et al. Vibration, acoustic, temperature, and motor current dataset of rotating machine under varying operating conditions for fault diagnosis[J]. *Data in Brief*, 2023, 48: 109049.



第一作者简介:古玉锋,男,1978年9月生,博士、副教授。主要研究方向为自动驾驶。曾发表《基于联合卷积变分自编码器和预测器的UWB定位算法》(《仪器仪表学报》2025年第46卷第1期)等论文。

E-mail: guyufeng@chd.edu.cn

欢迎订阅《振动、测试与诊断》

《振动、测试与诊断》由工业和信息化部主管,南京航空航天大学 and 全国高校机械工程测试技术研究会联合主办,是反映振动、动态测试及故障诊断学科领域的科研成果及其应用情况的技术性刊物。主要刊登国内外以振动测试与故障诊断为中心的动态测试理论、方法和手段的研究及应用方面的技术文献,包括实验测试技术、测试仪器的研制、方法和系统组成、信号分析、数据处理、参数识别与故障诊断以及有关装置的设计、使用、控制、标定和校准等,不拘泥于行业和测试项目。

本刊为 EI Compendex 数据库收录期刊和中文核心期刊,双月刊,每逢双月末出版,每本定价 30 元,全年 180 元。欢迎订阅和投稿,欢迎在本刊刊登各类广告和科技信息。

编辑部地址:南京市御道街 29 号 邮政编码:210016 电话:(025)84893332

邮发代号:28-239 E-mail: qchen@nuaa.edu.cn 网址: http://zdc.nuaa.edu.cn