

基于 MCNN-LSTM-Attention 的电机故障 诊断方法

于 枫, 姚一聪*

(沈阳化工大学 信息工程学院, 辽宁 沈阳 110142)

Motor Fault Diagnosis Method Based on MCNN-LSTM-Attention

Yu Feng, Yao Yicong*

(College of Information Engineering, Shenyang University of Chemical Technology,
Shenyang 110142, China)

Abstract: [Objective] To address the challenges of insufficient feature extraction, inadequate capture of temporal dependencies, and low diagnostic accuracy under noise interference in motor fault diagnosis under complex working conditions, a fault diagnosis method based on a multi-scale convolutional neural network, long short-term memory, and attention mechanism (MCNN-LSTM-Attention) is proposed. [Methods] First, through the MCNN module, the parallel convolutional layers were used to extract multi-scale local features from the vibration signals, addressing the problem of difficulty in comprehensively characterizing fault features. Then, the LSTM module was utilized to perform temporal modeling on the multi-scale feature sequences, deeply mining the temporal dependencies of the fault features. On this basis, the Attention mechanism was introduced to adaptively weight the temporal features, so as to focus on the key fault information and suppress irrelevant noise interference. Finally, the multiple modules worked collaboratively to solve the problems of incomplete feature representation and weak robustness of the diagnostic model. [Results] To comprehensively evaluate the robustness and adaptability of the proposed motor fault diagnosis method in practical applications, typical non-ideal factors such as load fluctuations and speed disturbances were simulated and introduced by emulating complex on-site operating conditions, and noise interferences of different intensities were superimposed during the signal acquisition process, so as to

construct a test scenario close to the real industrial environment. On this basis, the diagnostic model was verified using actual collected motor operating data. The experimental results showed that the method maintained high diagnostic accuracy under various complex operating conditions and different noise levels, and at the same time, it exhibited good generalization capability in tests across different operating conditions and fault types. [Conclusion] The proposed method achieves accurate fault diagnosis of motors under complex operating conditions. This result provides reliable technical support for practical engineering applications, and also offers useful reference and new insights for preventive maintenance measures in subsequent equipment operation.

Key words: motor; fault diagnosis; multi-scale convolutional neural network; long short-term memory network; attention mechanism

摘 要: 【目的】针对电机故障诊断在复杂工况下特征提取不充分、时序依赖关系捕捉不足及噪声干扰下诊断精度不高的问题,提出一种基于多尺度卷积-长短期记忆网络-注意力机制(MCNN-LSTM-Attention)的故障诊断方法。【方法】首先,通过 MCNN 模块使并行卷积层提取振动信号中的多尺度局部特征,解决难以全面表征故障特征的问题。然后,利用 LSTM 模块对多尺度特征序列进行时序建模,深入挖掘故障特征的时序依赖关系。在此基础上,引入 Attention 模块对时序特征进行自适应加权,以聚焦关键故障信息,抑制无关噪声干扰。最后,多个模块协同解决特征表示不全面与诊断模型鲁棒性不强的问题。【结果】为了全面评估所提电机故障诊断方法在实际应用中的鲁棒性与适应性,通过模拟现场复杂工况,引入负载波动、转速扰动等典型非理想因素,并在信号采集过程中叠加不同强度的噪声干扰,以构建贴近真实工业环

基金项目: 辽宁省教育厅科研项目(JYTMS20231483);辽宁省科技厅科研项目(2024011836-JH3/4700)

Research Project of Liaoning Provincial Department of Education (JYTMS20231483) and Research Project of the Science and Technology Department of Liaoning Provincial (2024011836-JH3/4700)

境的测试场景。在此基础上,利用实际采集的电机运行数据对诊断模型进行验证。试验结果表明,该方法在多种复杂工况和不同噪声水平下均能保持较高的诊断准确率,同时其在跨工况、跨故障类型的测试中表现出良好的泛化能力。【结论】所提方法实现了电机在复杂工况下的准确故障诊断,这一成果为实际工程应用提供了可靠的技术支撑,同时也为后续设备运行中的预防性维护措施提供了有益的参考和新的思路。

关键词: 电机;故障诊断;多尺度卷积神经网络;长短期记忆网络;注意力机制

0 引言

电机作为机电设备中的关键部件,在复杂的负载工况下易发生故障,进而直接影响设备运行的安全及可靠性。一旦电机发生故障,不仅会导致设备异常运行甚至损坏,影响正常生产,造成重大经济损失,还可能对操作人员的人身安全构成严重威胁^[1]。因此,准确诊断电机故障状态并及时开展设备维护,对于提高设备运行安全性和可靠性、避免因设备损坏造成的经济损失,具有重要的实际意义。

传统的电机故障诊断方法通常依赖于从原始振动信号中提取故障特征,而后其一般流程为:首先采用时频信号处理技术进行特征提取,常用方法包括奇异值分解^[2]、快速傅里叶变换^[3]、连续小波变换^[4]和变分模态分解^[5];然后将提取到的特征输入分类器,如支持向量机^[6]、极限学习机^[7]和贝叶斯网络^[8],以实现故障类型的识别。在相关研究中,Zheng 等人^[9]提出了一种融合变分模态分解和广义学习模型的故障诊断方法,该方法先利用变分模态分解对振动信号进行分解,再经预处理后通过广义学习模型对故障进行分类,准确率达到 97.48%。Liu 等人^[10]采用遗传变异粒子群算法对变分模态分解方法进行参数优化,用于处理故障信号,并根据滚动轴承故障机理提取相应的样本熵,从而有效提高了滚动轴承故障诊断的准确率。然而,变分模态分解在信号分解过程中对参数选择具有较强依赖性,在缺乏对机械故障特征充分识别的情况下,难以准确区分不同的故障类型^[11]。

随着工业大数据的不断拓展以及智能设备故障特征提取需求的持续增长,深度学习方法因其

强大的特征自学习能力,在故障诊断领域得到了越来越广泛的应用。与传统方法相比,深度学习模型能够自适应地从原始信号中挖掘采集信号中隐藏的特征,从而避免了繁琐的人工特征提取过程。在相关研究中,Liu 等人^[12]提出了一种基于一维卷积神经网络结合注意力机制(1-Dimensional Convolutional Neural Network, Attention Mechanism, 1D-CNN-Attention)的精锻机电机故障诊断方法,该方法直接以原始一维振动信号作为输入,实现端到端的故障识别。Zhu 等人^[13]则简化了信号处理流程,将主成分分析与深度信念网络相结合,自动提取关键故障特征并进行分类与诊断。Liu 等人^[14]针对深度学习方法在诊断过程中存在的数据需求量大和可解释性低等问题,引入了决策融合策略与迁移学习,优化模型诊断性能,从而有效提高了故障诊断准确率。此外,Lv 等人^[15]提出了基于多尺度卷积神经网络与决策融合相结合的滚动轴承故障诊断方法,通过多尺度特征提取增强了诊断精度。Yu 等人^[16]提出了基于堆叠长短期记忆网络(Long Short-Term Memory, LSTM)的分层算法,构建了滚动轴承故障诊断系统框架,利用 LSTM 的记忆遗忘机制,提取原始信号中的时间相关特征,达到了较高的识别精度。Hu 等人^[17]提出了一种多头注意力增强的图卷积神经网络模型,对输入的故障节点数据进行编码,并通过递归神经网络和非线性层实现电机故障类型的分类,在电故障诊断任务中取得了良好效果。Chen 等人^[18]提出了一种基于双流 CNN-LSTM 的故障诊断模型,进一步增强了模型在无人潜航器电机故障诊断中的有效性。同时,Zuo 等人^[19]开发了一种基于多尺度加权可见性图和多通道图卷积网络的方法,利用图神经网络对全局和局部特征的提取能力,解决了有限样本数据下的过拟合问题。Liu 等人^[20]提出了一种多尺度融合注意力 CNN 模型,通过注意力机制对不同尺度卷积模块提取的特征进行加权与融合,使网络能够动态地确定关键故障特征的优先级,从而提高识别精度,该方法在滚动轴承故障诊断中表现出良好的适应性。

上述方法虽在各自研究中取得了相应进展并表现出较高的诊断精度,但在复杂的工业环境下仍面临诸多挑战,主要体现在多源信号中

有效故障信息不足、多模态特征融合效果欠佳等方面,相关方法尚有待进一步完善。针对上述问题,本文提出了一种基于多尺度卷积-长短期记忆网络-注意力机制(Multi-Scale Convolutional Neural Network, Long Short-Term Memory, Attention Mechanism, MCNN-LSTM-Attention)的电机故障诊断方法。该方法首先建立用于电机故障诊断的 MCNN-LSTM 网络模型,利用多尺度卷积模块提取原始信号中的局部特征,并将所提取的多尺度特征输入 LSTM 层,以捕捉其序列依赖关系,增强特征表达的能力。然后在 MCNN-LSTM 模型之后引入注意力机制,对时序特征进行自适应加权处理,以聚焦关键故障信息,抑制无关噪声干扰。此外,该方法直接将原始一维振动信号作为模型输入,无需进行复杂的预处理操作,从而最大限度地保留原始故障特征,提高模型在复杂工况条件下的特征提取能力与适应性。

1 理论分析

1.1 卷积神经网络

卷积神经网络是一种前馈神经网络,其具有非凡的捕捉空间数据特征的能力。一个标准的 CNN 通常由一个输入层、一些卷积层、池化层、全连接层以及一个输出层组成,如图 1 所示。




图 1 CNN 基本结构图

Fig. 1 Basic structure of CNN

1.2 长短期记忆网络

长短期记忆网络的核心单元包括三个门:遗忘门 f_t 、输入门 i_t 和输出门 o_t 。遗忘门评估存储单元中的信息,并根据这一分析决定保留和丢弃什么。随后,输入门更新存储单元状态,而输出门则调节 LSTM 的输出,LSTM 单元结构如图 2 所示。

1.3 注意力机制

注意力机制是一种模仿人类注意力分配方




图 2 LSTM 单元结构图

Fig. 2 LSTM unit structure diagram

式的重要特征筛选方法。其核心优势在于,神经网络模型在处理输入数据时能够动态地调整关注焦点,有针对性地增强对关键信息的感知,从而帮助模型更准确地识别重要特征^[21]。注意力机制通过网络自主学习的方式,自动评估每个特征对诊断结果的贡献程度,并据此分配相应的权重。对于重要性较高的特征,赋予更大的权重以增强其表示效果;对于冗余或相关性较低的特征,则赋予较小的权重以抑制其影响。通过这种加权机制,模型能够有效聚焦于关键信息,最大程度地利用有限特征中的有效内容,从而显著提高诊断精度。

2 MCNN

与上述基础理论中的 CNN 结构类似,本文提出的 MCNN 算法模型由多个卷积块和池化块组成,主要区别在于 MCNN 为双路并行不同尺度的卷积核。双路并行多尺度卷积可以更全面地提取特征,第一路采用大尺度的卷积核提取更宽泛特征,捕捉整体趋势、长期依赖;第二路采用小尺度的卷积核来逐步增加网络深度提取更精细的高阶特征,捕捉细节变化、局部模式。这样做的好处是,不同尺寸卷积核具有不同大小的感受野,从而可以提取到低频率以及高频率的特征同时具备宏观和微观信息,将这些特征叠加起来形成多尺度特征。MCNN 结构如图 3 所示。

MCNN 算法的提出是针对一维振动信号所设计的方法,利用第一路 16×1 大卷积核自动学习短时特征,有效抑制高频噪声从而减小噪声对特征提取影响,构建的第二路 3×1 卷积核能够减少卷积核的参数,加深网络深度,并起到抑制过拟合的效果。MCNN 结构参数如表 1 所示。通过上述模型算法的设计以及 LSTM、Attention 的引入能有




图 3 MCNN 结构图

Fig. 3 MCNN structure diagram

效优化故障模型。

表 1 MCNN 结构参数

Tab. 1 MCNN structural parameters

序号	网络层	卷积核大小	卷积核数或步长
1	卷积层 1-1	16×1	64
2	池化层 1-1	2×1	2
3	卷积层 1-2	16×1	128
4	池化层 1-2	全局平均池化	全局平均池化
5	卷积层 2-1	3×1	32
6	池化层 2-1	2×1	2
7	卷积层 2-2	3×1	64
8	池化层 2-2	2×1	2
9	卷积层 2-3	3×1	128
10	池化层 2-3	全局平均池化	全局平均池化
11	特征融合	融合两支路特征	融合两支路特征
12	全连接	100	1
13	Softmax	10	1

3 电机故障诊断

3.1 故障诊断模型

CNN 具有多尺度卷积的特征学习能力^[22], LSTM 擅长处理非线性序列数据, 而注意力机制能够为不同特征分配差异化权重, 以突出关键特征并抑制无关信息。综合上述优势, 本文提出一种用于电机振动信号特征提取与故障分类诊断的 MCNN-LSTM-Attention 网络框架, 如图 4 所示。

该网络由输入层、多尺度卷积层、LSTM 层、注意力机制、全连接层以及输出层组成。将采集到的电机振动加速度信号通过滑动窗口处理, 得到训练模型的数据集, 并对数据进行归一化处理,




图 4 MCNN-LSTM-Attention 结构图

Fig. 4 Structure diagram of MCNN-LSTM-Attention

然后输入至 MCNN 网络中。第一路采用大卷积核, 用于从输入数据中自动提取振动信号中蕴含的宽泛特征信息; 第二路采用小卷积核, 进一步提取原始数据中深层次的基本特征。随后, 将两路提取的特征进行融合, 并传递至 LSTM 层, 以捕获序列中的时序依赖关系; 继而通过注意力机制对不同时序特征分配相应权重, 突出关键故障信息。最后, 经全连接层和输出层, 输出电机故障的诊断结果^[23]。

3.2 故障诊断流程

整个试验过程包括模型建立、初始化参数和故障诊断, 如图 5 所示。




图 5 MCNN-LSTM-Attention 流程图

Fig. 5 Flowchart of MCNN-LSTM-Attention

构建过程描述如下: (1) 提取样本数据集。使用滑动窗口对数据集进行重叠采样操作对分割后的样本添加标签并进行标准化。(2) 设置模型并初始化参数。(3) 故障诊断。通过多尺度卷积的特征提取和长短期网络对提取的多尺度特征时

序处理以及注意力机制的特征加权,从而对标准样本进行故障诊断。(4) 输出结果,并评估该模型的诊断能力。

4 试验结果与分析

4.1 数据集描述

本研究采用自搭建试验台采集的电机故障数据集作为试验数据。通过在电机及电流导线上人工设置典型故障类型,并叠加噪声干扰与复杂工况影响,以模拟真实运行环境,同时利用加速度传感器和电流钳同步采集电机在不同运行状态下的多源信号,如图 6 所示。该数据集基于实际电机运行物理过程采集,能够有效反映真实故障特征,避免纯仿真数据与工程实际之间可能存在的偏差,从而为后续故障诊断模型的验证提供可靠的数据基础^[24]。




图 6 故障数据采集试验台

Fig. 6 Motor fault data acquisition test platform

试验设备中使用的电机为商用小型三相异步电动机(型号 YE2-90S-4),主要参数为额定电压 380 V,额定电流 2.8 A(角接),额定功率 1.1 kW,额定频率 50 Hz,定子槽数为 36 槽,转子类型为鼠笼式铸铝转子,转子导条数为 28 根,轴承型号前后均为 6204-2Z(深沟球轴承)。其中电机内部主要包括轴承、绕组、转子、定子、导条等,电机外部有联轴器、接线端子、线路和辅助飞轮等。根据故障位置和故障类别建立数据集,一共获得了 8 种故障状态。使用标签 1 到 9 对 9 种电机状态进行分类,如表 2 所示。

表 2 中故障类型均设置为微弱故障而后进行识别。故障类型里转子不对中是将输出轴与负载轴两轴心偏移 0.15 mm,该偏移量仅引起轻微的径向振动变化;电压不平衡是采用三相调压器使三相电压幅值不等;断相是在某相串联一个 10 Ω 电阻,

模拟接触不良;转子弯曲变形是设置 0.05 mm 的弯曲量,检测微弱振动;轴承故障是在负载端轴承内圈设置宽 0.2 mm、深 0.1 mm 的微小凹陷使其运行时产生冲击振动;转子断条是将其有一根导条割断 1/2 使其振动异常来进行故障识别。

表 2 电机故障信息

Tab. 2 Motor fault information

序号	故障类型	故障类别样本	故障位置
1	正常	200	/
2	转子不对中	200	电机联轴器
3	电压不平衡	200	电机端子
4	断相	200	电机绕组
5	转子弯曲变形	200	电机转子
6	轴承故障	200	电机轴承
7	转子断条	200	电机导条
8	补充电压不平衡	200	电机线路
9	补充断相	200	电机接线盒

试验台在数据采集过程中对不同故障类型进行分类,以便评估故障等级、预测故障发展趋势并实施有效故障管理,从而及时调整试验平台运行参数,这不仅有利于后续模型的特征提取,也有助于提高设备的可用性与可靠性^[25]。

4.2 MCNN-LSTM-Attention 网络配置

所提出的 MCNN-LSTM-Attention 电机故障状态分类模型的网络配置,如表 3 所示。

由表 3 可知,所提出的 MCNN-LSTM-Attention 电机故障诊断模型有 19 层,输入层的样本长度为 1 024。第一路卷积层的核大小为 16×1 ,通道个数最多为 128,步幅为 1;第二路卷积层的核大小为 3×1 ,通道个数最少为 32,步幅为 1。LSTM 层有 128 个神经元,全连接致密层有 10 个神经元。Softmax 功能用于分类和输出电机的振动加速度信号。使用 ReLU 函数激活卷积层,通过正则化保持更好的尺度不变性,降低对网络初始化的敏感性,避免梯度消失,加快网络训练速度。

4.3 对比试验

为了验证所提模型的性能,将基于试验台故障数据的深度学习模型进行验证,均以多次试验取平均值的结果进行比较^[26]。图 7 展示了 4 种模型在 100 个训练周期内(每轮迭代 7 次)的准确率变化曲线。由图 7 可知,本文所提模型在前 20 个周期

内验证准确率逐步上升,经过 40 个周期后趋于收敛并无限接近 100%,且在整个训练过程中始终保持在 99% 以上。相比之下,其余 3 种模型均存在不同程度的波动或收敛稳定性不足等问题。

表 3 网络配置表

Tab. 3 Network configuration table		
编号	名称	配置参数或功能
1	输入层	1024×1×1 个维度
2	卷积层 1-1	64 16×1
3	池化层 1-1	最大池化步幅[2 2]
4	卷积层 1-2	128 16×1
5	池化层 1-2	二维全局平均池化
6	扁平化	数据压缩为 1 维
7	卷积层 2-1	32 3×1
8	池化层 2-1	最大池化步幅[2 2]
9	卷积层 2-2	64 3×1
10	池化层 2-2	最大池化步幅[2 2]
11	卷积层 2-3	128 3×1
12	池化层 2-3	二维全局平均池化
13	扁平化	数据压缩为 1 维
14	丢弃层	丢弃 30% 防过拟合
15	LSTM	128 个隐藏单元
16	注意力机制	4 个注意力头 16 键
17	全连接层	输出尺寸 10
18	Softmax	计算十种状态概率
19	输出层	分类输出




图 7 准确率曲线

Fig. 7 Accuracy curves

为对所提模型在故障诊断任务中的有效性进行基准测试,我们在同一数据集上开展了与其他 3 种模型的对比分析。如图 8 所示,本文模型在前 40 个周期内迅速将训练损失降至约 0.05%,并

在此后保持平稳收敛。相比之下,其余模型虽也在 40 个周期前将损失降至较低水平,但在收敛过程中均出现不同程度的损失波动^[27]。




图 8 训练损失曲线

Fig. 8 Training loss curves

上述结果表明,本文所提模型在该数据集上具有较高的稳定性与泛化能力。相比之下,CNN-LSTM 与 CNN-LSTM-Attention 模型在训练初期虽能将损失较快收敛至稳定值,但其准确率提升有限,表明二者在处理序列信号时存在特征提取能力不足的问题,无法充分挖掘关键故障信息。而 MCNN-LSTM 模型虽然能够达到较高的训练准确率,但其在训练过程中损失曲线和准确率曲线均出现明显波动,且其测试准确率低于本文所提模型,说明该模型在收敛稳定性和泛化性能方面仍存在不足。

表 4 列出了四种模型在故障诊断任务中的准确率对比结果(均为平均值)。可以看出,MCNN-LSTM-Attention 模型的准确率在所有对比模型中表现最佳,相较于 CNN-LSTM 模型,准确率提升了 1.5%,提升幅度最为显著;相较于 MCNN-LSTM 模型,准确率略有提高,表明引入注意力机制进行特征加权处理能有效提升诊断性能;而相较于 CNN-LSTM-Attention 模型,准确率同样略高,说明引入多尺度卷积有助于更充分地提取故障特征,进一步提升诊断准确率。

同时,从表 4 还可知,上述四种模型在各类故障诊断任务中的准确率均维持在 99% 以上,进一步验证了基于深度学习模型的电机故障诊断方法具有较高的识别精度。综合以上对比分析结果可知,本文所提模型能够充分挖掘电机故障数据中的深层时序与局部特征,具备良好的故障诊断性能与工程应用潜力。

表 4 模型故障准确率对比结果

Tab. 4 Comparison results of model fault accuracy

序号	模型	准确率/%
1	MCNN-LSTM-Attention	99.6
2	MCNN-LSTM	98.8
3	CNN-LSTM-Attention	98.7
4	CNN-LSTM	98.1

为了直观、全面地评估本文所提方法与其他

方法在各类故障样本中的分类性能,本文采用混淆矩阵^[28]对试验结果进行可视化呈现,如图 9 所示。通过对该矩阵的比较分析可知,所提模型对各故障类别的分类精度较高,表明该模型具备准确识别和区分多种故障类型的能力。相比之下,其他对比方法在某些故障类别上均存在不同程度的误分类现象,这进一步凸显了 MCNN-LSTM-Attention 模型在故障分类任务中的优越性能及其在复杂工况下开展故障诊断的应用潜力。




图 9 不同模型在各类故障样本中的分类性能

Fig. 9 Classification performance of different models in various fault samples

为了能直观地分析各种方法的诊断性能,对模型提取的特征进行可视化处理,如图 10 所示。图中基于 MCNN-LSTM-Attention 的故障识别得到的特征方法在可视化图中表现出显著的分异性。同一类别的样本紧密聚集在一起,而不同类别的样本则明显分离重叠最小,反映出所提模型的有效性,并突出了其在故障识别任务中的优异分类性能。

4.4 消融试验

为验证本文所提出 MCNN-LSTM-Attention 模型的有效性,对该模型设计如下三组消融试验。

(1) 方案设计 1: 去掉模型中的注意力机制,

测试 MCNN-LSTM 的准确率。

(2) 方案设计 2: 去掉模型中的 LSTM, 测试 MCNN-Attention 的准确率。

(3) 方案设计 3: 去掉模型中的 LSTM 和注意力机制, 测试 MCNN 的准确率。

表 5 为消融试验的结果,可以看出去掉不同模块对模型性能均有不同影响。仅使用 MCNN 时准确率仅为 92.5%; MCNN 中仅添加注意力机制时, MCNN-Attention 的准确率为 98.5%; MCNN 中仅添加 LSTM 时准确率为 98.8%; 同时添加 LSTM 和 Attention 时模型准确率为 99.6%。

为了验证各模块在模型中的具体作用,图 11




图 10 分类特征可视化

Fig. 10 Visualization of classification features

以混淆矩阵的形式展示了不同模块组合下的验证结果。由图 11 可知,在多次试验取平均值的条件下,MCNN-LSTM-Attention 模型的表现最优,对 10 种故障类型的诊断正确率均为最高。该结果充分表明,LSTM 和注意力机制能够有效辅助模型提取关键故障特征,从而增强模型对故障模式的识别能力,显著提升整体性能^[29]。

表 5 消融试验结果

Tab. 5 Ablation test results		
序号	模型	准确率/%
1	MCNN	92.5
2	MCNN- Attention	98.5
3	MCNN-LSTM	98.8
4	MCNN-LSTM- Attention	99.6

上述试验结果充分验证了 MCNN-LSTM-Attention 模型在电机故障诊断中的有效性,LSTM 和注意力机制在提升模型准确率、训练稳定性和特征提取能力方面发挥了重要作用^[30]。

5 结语

本文提出了一种面向电机振动信号特征提

取与故障分类诊断的 MCNN-LSTM-Attention 模型。试验结果表明,该方法有效提升了故障诊断系统的综合性能,为复杂工况下的设备监测提供了一种新的技术路径。在该模型网络结构设计中,MCNN 模块作为特征提取前端,通过并行多尺度一维卷积层提取振动信号中的多尺度局部特征;LSTM 模块则对提取的多尺度特征序列进行时序建模,捕捉其长期依赖关系;在此基础上,引入注意力机制对 LSTM 输出的各时序特征进行自适应权重分配,从而增强模型对关键故障特征的判别能力,并提升其在噪声环境下的鲁棒性。

通过在试验台采集的真实数据集上进行验证,充分证明了该模型的有效性。试验结果表明,MCNN-LSTM-Attention 模型在平稳工况下均能保持非常高的诊断准确率,进一步验证了注意力机制在提升模型鲁棒性方面的关键作用,以及多尺度特征与时序建模相结合的必要性。

未来将进一步探索模型在强噪声干扰、跨工况迁移及小样本条件下的适应能力,以满足工业现场对实时监测技术的实际需求。




图 11 不同模块组合下的验证结果

Fig. 11 Validation results under different module combinations

利益冲突声明

所有作者声明不存在利益冲突。

All authors disclose no relevant conflict of interests.

作者贡献

姚一聪进行了方案设计、内容总结、论文撰写与试验研究,于枫参与了论文的审核与修改。所有作者均阅读并同意了最终稿件的提交。

The conceptual design, content summarization, manuscript writing and experimental research was responsible by Yao Yicong. Yu Feng participated in the review and revision of the manuscript. All authors have read and approved the final version of the manuscript for submission.

参考文献

- [1] 张晓英, 段赛赛, 张兴平, 等. 融合时空相关性和权重系数分配的风电机组出力异常值处理方法[J]. 电力建设, 2024, 45(6): 100-110.
Zhang X Y, Duan S S, Zhang X P, et al. Method for

handling outliers of wind turbine output integrating spatiotemporal correlation and weight coefficient allocation[J]. Electric Power Construction, 2024, 45(6): 100-110.

- [2] Xu S, Chatterton S, Pennacchi P. Rolling element bearing diagnosis based on singular value decomposition and composite squared envelope spectrum[J]. Mechanical Systems and Signal Processing, 2021, 148: 107174.
- [3] Lee J S, Yoon T M, Lee K B. Bearing fault detection of IPMSMs using zoom FFT[J]. Journal of Electrical Engineering and Technology, 2016, 11(5): 1235-1241.
- [4] Yang G, Hu Y, Shi Q. Fault diagnosis of bearings based on SSWT, Bayes optimisation and CNN[J]. Polish Maritime Research, 2023, 30(3): 132-141.
- [5] Huang D, Li Y, Guan S, et al. A novel collaborative diagnosis approach of incipient faults based on VMD and SCN for rolling bearing[J]. Optimal Control Applications and Methods, 2023, 44(3): 1617-1631.
- [6] Zhang X, Zhao J, Teng H, et al. A novel faults detection method for rolling bearing based on RCMDE

- and ISVM [J]. *Journal of Vibroengineering*, 2019, 21(8): 2148-2158.
- [7] Yang Y, Xi C. Rolling bearing fault diagnosis based on MFDFA-SPS and ELM [J]. *Mathematical Problems in Engineering*, 2022, 1: 4034477.
- [8] Jiang Z, Zhou J, Ma Y. Fault diagnosis for rolling bearing based on parameter transfer Bayesian network [J]. *Quality and Reliability Engineering International*, 2022, 38(8): 4291-4308.
- [9] Zheng J, Yuan Y, et al. Study on a novel fault diagnosis method based on VMD and BLM [J]. *Symmetry*, 2019, 11: 747.
- [10] 刘建昌, 权贺, 于霞, 等. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断[J]. *自动化学报*, 2022, 48(3): 808-819.
- Liu J C, Quan H, Yu X, et al. Fault diagnosis of rolling bearing based on parameter optimized VMD and sample entropy [J]. *Acta Automatica Sinica*, 2022, 48(3): 808-819.
- [11] Liu W, Liu Y, Chen Y K. A review of variational mode decomposition in seismic data analysis [J]. *Surveys in Geophysics*, 2023, 44: 323-355.
- [12] 刘忠兴, 曹立文. 基于 1D-CNN-Attention 的精锻机电机故障诊断[J]. *防爆电机*, 2025, 60(4): 107-112.
- Liu Z X, Cao L W. Fault diagnosis of precision forging machine motor based on 1D-CNN-Attention [J]. *Explosion-Proof Electric Machine*, 2025, 60(4): 107-112.
- [13] Zhu J, Hu T, Jiang B, et al. Intelligent bearing fault diagnosis using PCA-DBN framework [J]. *Neural Computing and Applications*, 2020, 32: 10773-10781.
- [14] 刘婷婷, 王哲铭, 于文英, 等. 基于决策融合方法和迁移学习的齿轮箱故障诊断[J]. *济南大学学报(自然科学版)*, 2025, 39(3): 379-388.
- Liu T T, Wang Z M, Yu W Y, et al. Fault diagnosis of gearbox based on decision fusion method and transfer learning [J]. *Journal of University of Jinan (Natural Science Edition)*, 2025, 39(3): 379-388.
- [15] Lv D, Wang H, Che C. Multiscale convolutional neural network and decision fusion for rolling bearing fault diagnosis [J]. *Industrial Lubrication and Tribology*, 2021, 73(3): 516-522.
- [16] Yu L, Qu J, Gao F, et al. A novel hierarchical algorithm for bearing fault diagnosis based on stacked LSTM [J]. *Shock and Vibration*, 2019, 1: 2756284.
- [17] 吕栋腾, 胡春龙. 基于图卷积网络的电机故障诊断研究[J]. *计算技术与自动化*, 2025, 44(4): 150-153.
- Lyu D T, Hu C L. Research on motor fault diagnosis based on graph convolutional network [J]. *Computing Technology and Automation*, 2025, 44(4): 150-153.
- [18] 陈雪倩, 沈钧戈, 白俊强, 等. 基于双流 CNN-LSTM 的 UAV 电机故障诊断方法[J]. *导弹与航天运载技术(中英文)*, 2025(4): 59-66.
- Chen X Q, Shen J G, Bai J Q, et al. Fault diagnosis method for UAV motor based on dual-stream CNN-LSTM [J]. *Missiles and Space Launch Technology (Chinese and English)*, 2025(4): 59-66.
- [19] Zuo D, Tang T, Chen M. Rolling bearing fault diagnosis based on multi-scale weighted visibility graph and multi-channel graph convolution network [J]. *Measurement Science and Technology*, 2023, 34(11): 115019.
- [20] Liu X, Lu J, Li Z. Multiscale fusion attention convolutional neural network for fault diagnosis of aero-engine rolling bearing [J]. *IEEE Sensors Journal*, 2023, 23(17): 19918-19934.
- [21] Xu F, Sui Z, Ye J, et al. Ternary precursor centrifuge rolling bearing fault diagnosis based on adaptive sample length adjustment of 1DCNN-SeNet [J]. *Processes*, 2024, 12(4): 702.
- [22] 申张亮, 陈旖旎, 杨阳, 等. 基于多特征图谱和 CNN-BKA-LSSVM 的隔离开关故障诊断方法[J]. *电机与控制应用*, 2025, 52(7): 710-720.
- Shen Z L, Chen Y N, Yang Y, et al. Fault diagnosis method for disconnecter based on multi-feature map and CNN-BKA-LSSVM [J]. *Electric Machines & Control Application*, 2025, 52(7): 710-720.
- [23] 卢禹卓, 安群涛, 赵孟佶, 等. 基于矢量遍历的 CSI-PMSM 驱动系统短路故障诊断与定位方法[J/OL]. *中国电机工程*, 1-13 [2026-06-17]. <https://doi.org/10.13334/j.0258-8013.pcsee.252531>.
- Lu Y Z, An Q T, Zhao M J, et al. Short-circuit fault diagnosis and localization method for CSI-PMSM drive system based on vector traversal [J/OL]. *Proceedings of the CSEE*, 2026, 1-13 [2026-06-17]. <https://doi.org/10.13334/j.0258-8013.pcsee.252531>.
- [24] 崔佳嘉, 马宏忠. 基于 CEEMDAN-小波阈值和 3D-

- CNN 的变压器铁心松动故障诊断模型[J]. 电机与控制应用, 2022, 49(10): 46-52.
- Cui J J, Ma H Z. Fault diagnosis model for transformer core looseness based on CEEMDAN-wavelet threshold and 3D-CNN [J]. Electric Machines & Control Application, 2022, 49(10): 46-52.
- [25] 宋建明, 宋欣杰, 金一鸣. 新能源汽车驱动电机故障诊断与维修技术研究[J]. 汽车维护与修理, 2026(3): 104-106.
- Song J M, Song X J, Jin Y M. Research on fault diagnosis and maintenance technology of new energy vehicle drive motor[J]. Automobile Maintenance and Repair, 2026(3): 104-106.
- [26] 钱铁群, 张孜乐, 杨依林, 等. 基于改进经验小波变换的永磁同步电机故障诊断策略[J]. 电机与控制应用, 2025, 52(1): 12-21.
- Qian Y Q, Zhang Z L, Yang Y L, et al. Fault diagnosis strategy for permanent magnet synchronous motor based on improved empirical wavelet transform [J]. Electric Machines & Control Application, 2025, 52(1): 12-21.
- [27] 郭家豪, 欧阳晖, 刘振兴. 基于 APSO-SSVM 的异步电动机转子故障诊断[J]. 电机与控制应用, 2023, 50(10): 91-99.
- Guo J H, Ouyang H, Liu Z X. Rotor fault diagnosis of asynchronous motor based on APSO-SSVM [J]. Electric Machines & Control Application, 2023, 50(10): 91-99.
- [28] 汤占军, 孙润发. 基于多尺度模糊熵和 STOA-SVM 的风机轴承故障诊断[J]. 电机与控制应用, 2021, 48(12): 66-70.
- Tang Z J, Sun R F. Fault diagnosis of fan bearing based on multi-scale fuzzy entropy and STOA-SVM [J]. Electric Machines & Control Application, 2021, 48(12): 66-70.
- [29] 张家俊. 基于 SDO-RF 的电动拖拉机驱动电机故障诊断方法[J]. 农机科技推广, 2026(2): 56-61.
- Zhang J J. Fault diagnosis method for electric tractor drive motor based on SDO-RF [J]. Agricultural Machinery Technology Extension, 2026(2): 56-61.
- [30] 张卫星, 宋树权, 于霜, 等. 基于双流自适应网络的电机轴承故障诊断[J]. 现代制造工程, 2026(1): 123-134.
- Zhang W X, Song S Q, Yu S, et al. Fault diagnosis of motor bearing based on dual-stream adaptive network [J]. Modern Manufacturing Engineering, 2026(1): 123-134.

收稿日期:2026-03-10

收到修改稿日期:2026-04-20

作者简介:

于 泓(1987—),男,博士,讲师,研究方向为基于深度学习的复杂工业故障诊断,lnasyufeng@126.com;

* 通信作者:姚一聪(1997—),男,硕士研究生,研究方向为基于深度学习的电机轴承故障诊断,1614378044@qq.com。