

DOI: 10.19650/j.cnki.cjsi.J2412385

基于注意力机制与多源信息融合的 变工况轴承故障诊断*

乔卉卉¹, 赵二贤¹, 郝如江¹, 李东升², 王勇超¹

(1. 石家庄铁道大学 机械工程学院 石家庄 050043; 2. 中铁十四局集团装备有限公司 南通 226000)

摘要: 针对轴承在变工况下工作时受环境噪声和工况变化的干扰, 现有的基于单源信号的轴承故障诊断方法因单源信号难以提供全面且稳定的故障信息, 导致诊断效果不理想的问题, 提出一种基于注意力机制的多源信息融合网络模型 (MSIFNM)。该模型的多尺度特征提取模块可以提取更充足的故障特征信息; 双阶段注意力模块从多个维度增强对工况变化不敏感的故障特征; 多源信息特征加权模块根据不同传感器信号对不同故障的敏感程度, 自适应地对多源信息进行权重分配; 特征融合与类别输出模块实现对加权后的特征进一步融合与特征提取, 再经全连接层和 Softmax 层输出分类结果。采用变转速和变负载轴承故障数据集对本文所提的 MSIFNM 模型进行实验验证, 实验结果表明, MSIFNM 可以有效实现多源信息融合特征提取, 提高变工况条件下轴承故障诊断的准确性、稳定性和工况自适应性。

关键词: 变工况轴承故障诊断; 多源信息融合; 注意力机制; 卷积神经网络

中图分类号: TH165.3 文献标识码: A 国家标准学科分类代码: 460.40

Attention mechanism and multi-source information fusion-based method for bearing fault diagnosis under variable operating conditions

Qiao Huihui¹, Zhao Erxian¹, Hao Rujiang¹, Li Dongsheng², Wang Yongchao¹

(1. School of Mechanical Engineering, Shijiazhuang Tiedao University, Shijiazhuang 050043, China;

2. China Railway 14th Bureau Group Equipment Corporation Limited, Nantong 226000, China)

Abstract: When bearings operate under variable conditions, they are affected by environmental noise and fluctuations in operating parameters. Existing bearing fault diagnosis methods relying on single-source signals struggle in these situations because such signals often fail to provide comprehensive and stable fault information. To address this issue, this paper proposes a multi-source information fusion network model (MSIFNM) based on an attention mechanism. The model's multi-scale feature extraction module captures more detailed fault features, while the two-stage attention module enhances features that are less sensitive to changes in operating conditions. The multi-source information feature weighting module adaptively assigns weights to the features based on their sensitivity to faults. The feature fusion and classification output module further integrates these weighted features and delivers classification results through fully connected and softmax layers. To validate the effectiveness of the proposed MSIFNM model, bearing datasets under variable speed and load conditions were used. Experimental results demonstrate that the MSIFNM model significantly improves the accuracy, stability, and adaptability of bearing fault diagnosis under variable operating conditions.

Keywords: bearing fault diagnosis under variable operating conditions; multi-source information fusion; attention mechanism; convolutional neural network

收稿日期: 2024-01-13 Received Date: 2024-01-13

* 基金项目: 国家自然科学基金项目 (12202287)、河北省高等学校科学技术研究项目 (QN2022141)、中铁十四局集团装备有限公司科研项目 (CRCC14-ZB-KYHT-2023-002)、河北省市场监督管理局科研计划项目 (2023ZC24) 资助

0 引言

轴承作为旋转机械中应用最广泛的关键零部件之一,其运行状态直接影响着整机的性能。据统计,旋转机械故障中滚动轴承故障占比已达30%^[1]。随着我国工业的快速发展,轴承需要经常运行在变转速和变负载的工况条件下,这使轴承更容易发生各种故障。因此,变工况轴承故障诊断的研究一直是研究领域的热点。

自2006年HINTON首次提出深度学习后,基于深度学习的智能故障诊断已成为故障预测与健康领域的重要发展方向^[2]。对于基于深度学习模型的变工况轴承故障诊断方法,从模型角度分析,通常在恒工况下模型可以展现出优异的诊断性能,但是在变工况下由于模型训练集与测试集数据不满足独立同分布假设,模型出现领域漂移问题,导致训练好的模型用于未知随机工况下的监测数据时诊断性能大幅下降^[3];从数据源角度分析,当轴承运行在变工况条件下时,由于单个传感器采集的单源信息所含设备健康状态信息不完备,如果仅使用单源信息作为故障诊断模型的输入,会导致诊断结果的稳定性和可靠性不足。

为消除工况变化对模型性能的影响,研究人员除了采用阶次跟踪^[4]、阶次循环平稳分析^[5]以及时频分析^[6]等传统方法外,还结合机器学习与深度学习算法提出了多种解决方案。例如, Ji 等^[7]提出了一种结合阶次跟踪算法和卷积神经网络(convolutional neural networks, CNN)的诊断方案,实现变转速轴承故障诊断; Li 等^[8]提出了一种距离度量学习算法和 CNN 相结合的方案,实现变负载轴承故障诊断; Qiao 等^[9]引入自适应加权卷积模块增强对故障敏感而对工况变化不敏感的特征,构建了自适应加权卷积神经网络,对变工况条件下的轴承进行故障识别。

为解决单源信息不完备的问题,研究人员利用由多个传感器信号组成的多源信息获取更加完备的设备健康状态信息,构建多源信息融合模型得到更加稳定可靠的诊断结果。现阶段在基于多源信息融合的故障诊断研究中,一方面是基于相同信号类型的多源信息融合故障诊断,例如 Chen 等^[10]将垂直与水平振动信号融合后输入深度 CNN 进行诊断; Li 等^[11]将3个正交方向的振动信号融合后输入带有空洞卷积的 CNN 中,实现了更高的诊断准确率。另一方面是基于不同信号类型的多源信息融合故障诊断,例如 Zhang 等^[12]使用残差金字塔算法融合振动与声信号,再使用二维 CNN 与 AdaBoost 算法进行分类; Xie 等^[13]提出了一种基于多个不同传感器信号融合和 CNN 的新型智能诊断方法; Wang 等^[14]从振动与声学信号中提取特征,并使用一维 CNN 融合特征,实现了更高的诊断精度; Dong 等^[15]提出一种融合振动、电压和声

信号的一维 CNN 的故障诊断方法,并采用了结合马氏距离的 3σ 准则去除多源数据中的异常值; Liu 等^[16]应用小波包分解提取电流与振动信号的时频特征,实验结果表明组合特征可以获得更高的诊断精度。

上述研究分别提高了基于单源信息的变工况故障诊断的精度和基于多源信息融合的恒工况条件下的故障诊断的精度和稳定性,但是目前对基于多源信息融合的变工况轴承故障诊断方法的研究不足。基于多源信息融合的变工况轴承故障诊断存在2个方面的难点:1) 需要从多源信号中提取不受工况影响的故障敏感特征;2) 需要考虑不同信号源对不同故障的敏感度差异。

本文提出了一种适用于变工况轴承故障诊断的多源信息融合网络模型(multi-source information fusion network model, MSIFNM)。主要贡献包括:1) 将多尺度 CNN 与双阶段注意力机制模块相结合,分别从不同传感器信号中提取对工况变化不敏感的故障特征,增强了模型的工况自适应能力;2) 通过多源信息特征加权模块,使模型自适应地根据不同信号源对不同故障的敏感度差异,实现多源信息特征的自适应加权融合,进一步增强故障敏感特征;3) 分别在变转速和变负载条件下进行 MSIFNM 模型结构的消融实验以及基于不同信号源的对比实验,全面衡量模型在变工况条件下的性能。

1 卷积神经网络

CNN 是一类具有深层结构的神经网络,具备自动提取深层特征的能力,近年来在故障诊断领域应用广泛。经典的 CNN 模型主要包括输入层、卷积层、池化层、全连接层和 Softmax 层,如图1所示。




图1 CNN 的基本结构

Fig. 1 Basic structure of CNN

卷积和池化是 CNN 的核心,分别起着提取特征和压缩参数的作用。首先,数据经输入层输入网络,由反复交替的卷积池化操作提取特征;然后,特征图在全连接层之前铺平为一维向量;最后经全连接层和 Softmax 层输出不同类别的概率,实现故障分类。其中卷积过程可以表示为:

$$y_j = f\left(\sum_{i=1}^n (x_i * w_i) + b_i\right) \quad (1)$$

式中: y_j 为第 j 个输出; n 为卷积核的个数; x 为输入; $*$ 为卷积运算符; w_i 为第 i 个卷积核; b_i 为偏置项; $f(\cdot)$ 为 ReLU 激活函数。

2 网络模型

为进一步提高变工况条件下多源信息的自适应融合度和诊断准确率, 本文提出基于多源信息融合的故障诊断模型, MSIFNM 的整体模型结构如图 2 所示。MSIFNM 模型包含 4 个主要模块: 1) 多尺度特征提取模块; 2) 双阶段注意力模块; 3) 多源信息特征加权模块; 4) 特征融合与类别输出模块。

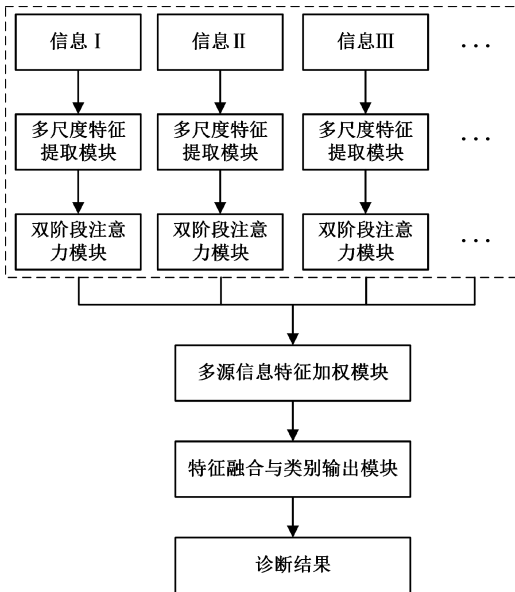


图 2 MSIFNM 的整体模型结构

Fig. 2 The overall model structure of MSIFNM

2.1 多尺度特征提取模块

轴承滚子经过故障部位时产生的周期性振动冲击信号成分比其他信号成分包含更多有意义的故障信息^[17], 但在变转速下冲击信号在时域和频域上会随转速变化而变化, 在时域上的特征表现为冲击信号出现在不同的时间尺度上, 在频域上的特征表现为冲击信号出现在不同的频带中。传统 CNN 仅在单一尺度上提取特征, 会导致变工况下提取的特征不完备, 而多尺度 CNN 可在不同尺度上提取信息, 因此在变工况条件下结合多尺度 CNN 来提取更完备的故障特征是必要的。多尺度特征提取模块的结构如图 3 所示。

首先, 在原始信号上使用宽卷积核提取特征, 宽卷积核充当低通滤波器, 卷积后的特征既可以有效减小高频噪声, 又可以抑制数据过拟合^[18-19]。其卷积过程具体计算如式(2)所示。

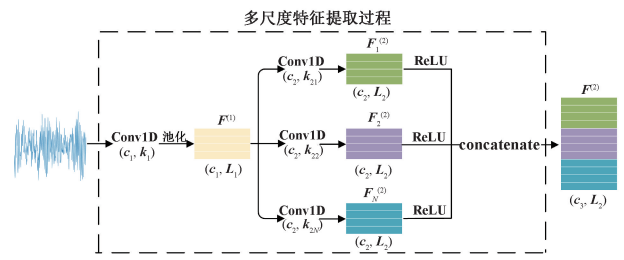


图 3 多尺度特征提取模块

Fig. 3 Multi-scale feature extraction module

$$\mathbf{F}^{(1)} = [f_1(\mathbf{k}_1 * \mathbf{x} + \mathbf{b}); \dots; f_N(\mathbf{k}_N * \mathbf{x} + \mathbf{b})] \quad (2)$$

式中: \mathbf{k}_1 为通道内的卷积核; $*$ 为卷积运算符; \mathbf{x} 为输入信号; \mathbf{b} 为卷积核的偏置项; $f(\cdot)$ 为 ReLU 激活函数; c_1 为输出通道数, c_1 个通道组成输出特征 $\mathbf{F}^{(1)}$ 。

卷积后每个通道内的输出长度为 L_1 , 特征 $\mathbf{F}^{(1)}$ 的尺寸为 (c_1, L_1) 。然后, 采用不同大小卷积核的卷积层对上一层的输出特征进行并行卷积, 即 N 个一维卷积层同时对特征 $\mathbf{F}^{(1)}$ 进行卷积, 每一个卷积层都会输出 c_2 个通道, 卷积层的卷积步长均设置为 1, 然后经过 ReLU 激活函数激活后再沿着通道轴拼接, 最终输出特征的总通道数 $c_3 = N \times c_2$ 。使用不同尺寸的卷积核提取不同时间尺度上的特征, 极大丰富了故障特征信息。在卷积过程中采用零元素填充确保不同卷积层能有相同的输出长度 L_2 , 从而在拼接层中顺利拼接不同通道的输出特征。整个拼接过程的计算表达式为:

$$\mathbf{F}_i^{(2)} = f(\mathbf{k}_{2i} * \mathbf{F}^{(1)} + \mathbf{b}) \quad (3)$$

$$\mathbf{F}^{(2)} = \text{con}_i^N[\mathbf{F}_i^{(2)}] \quad (4)$$

式中: \mathbf{k}_{2i} 为第 i ($i = 1, 2, \dots, N$) 个尺度使用的卷积核; $\mathbf{F}^{(1)}$ 为输入特征; \mathbf{b} 为卷积核的偏置项; $f(\cdot)$ 为 ReLU 激活函数; con 为拼接函数; $\mathbf{F}_i^{(2)}$ 为第 i ($i = 1, 2, \dots, N$) 个尺度的特征, 特征 $\mathbf{F}^{(2)}$ 的尺寸为 (c_3, L_2) 。

2.2 双阶段注意力模块

每一种传感器信号经多尺度特征提取模块后, 再由双阶段注意力模块从通道和空间 2 个维度对多尺度特征进行加权调制, 双阶段注意力模块如图 4 所示。




图 4 双阶段注意力模块

Fig. 4 Two-stage attention module

双阶段注意力模块是提高模型工况自适应能力的关键模块, 可在通道维度上增强对轴承健康状态更敏感的通道特征并抑制对工况变化敏感的通道特征, 在空间维度上增强每个通道内更具有故障鉴别性的特征并抑制无

用特征。

双阶段注意力模块的通道阶段详细结构如图 5 所示,通道阶段的运算过程与经典的 SENet^[20] 不同之处在于没有采用最大池化和平均池化来压缩特征,而是采用时间分布式的一维卷积层 (time-distributed 1D convolution, TD-Conv1D) 依次覆盖每条通道内的全部特征实现全局卷积,详细描述如图 6 所示。




图 5 通道阶段注意力

Fig. 5 Attention of channel stage




图 6 时间分布式一维卷积

Fig. 6 Time-distributed 1D convolution

该过程把每条通道内的特征卷积为向量中的 1 个值,最终得到 1 个一维向量 $V^{(1)}$ 。之后再经压缩与激发过程生成一维权重向量 $V^{(2)}$,将权重向量与输入特征进行逐元素相乘,即对不同的通道赋予不同的权重,实现对不同通道特征的增强或抑制作用。其具体的数学表达式为:

$$V^{(2)} = \sigma(w_1 f(w_0(V^{(1)}) + b_0) + b_1) \quad (5)$$

$$F^\wedge = V^{(2)} \odot F^{(2)} \quad (6)$$

式中: $\sigma(\cdot)$ 为 sigmoid 函数; $f(\cdot)$ 为 ReLU 函数; w_0, w_1 为全连接层的参数; b_0, b_1 为偏置项; \odot 为逐元素相乘; F^\wedge 为通道阶段注意力的输出特征。

双阶段注意力模块的空间阶段详细结构如图 7 所示。




图 7 空间阶段注意力

Fig. 7 Attention of space stage

空间阶段的运算过程:首先沿着通道轴进行最大池化和平均池化操作,再将 2 个通道拼接起来,采用卷积核

大小为 3 的二维卷积操作计算用于权重分配的空间权重矩阵 $V^{(3)}$,该权重矩阵对要增强或抑制的空间特征位置进行编码,卷积计算中填充方式选择为 same 以使输出具有与原始输入相同的大小;最后,将特征 F^\wedge 与生成的空间权重矩阵 $V^{(3)}$ 沿通道轴逐元素相乘,实现空间特征加权。其具体的数学表达式为:

$$V^{(3)} = \sigma(\text{conv}^3([\text{Maxpool}(F^\wedge); \text{Avgpool}(F^\wedge)])) \quad (7)$$

$$F^{(s)} = V^{(3)} \odot F^\wedge \quad (8)$$

式中: conv^3 表示卷积核大小为 3 的卷积操作;Maxpool 为最大池化操作;Avgpool 为平均池化操作; $F^{(s)}$ 为空间阶段注意力的输出特征。

2.3 多源信息特征加权模块

本文在模型中融入多源信息特征加权模块,旨在根据不同传感器信号源对故障类型的敏感差异性,自适应地对多源信息特征进行权重分配,使模型关注故障敏感度更高的传感器信号源的特征。

多源信息特征加权模块如图 8 所示。




图 8 多源信息特征加权模块

Fig. 8 Module for weighting multi-source information features

其运算过程为:使用时间分布式的三维卷积层 (time-distributed 3D convolution, TD-Conv3D) 依次对不同传感器信号提取特征,所有传感器信息特征经三维卷积后得到与传感器相同数量的一维向量,再经过压缩与激发得到一维权重向量,最后将权重与不同传感器信号提取的特征相乘实现权重分配,起到对不同传感器信息特征增强和抑制的作用。其具体的数学表达式为:

$$F^{final} = \text{con}_n^T [w_l \odot F_l^{(s)}] \quad (9)$$

式中: $F_l^{(s)}$ 为第 l ($l = 1, 2, \dots, n$) 个传感器信号中提取出的信息特征; w_l 为特征 $F_l^{(s)}$ 对应的权重; \odot 为逐元素相乘。

2.4 特征融合与类别输出模块

特征融合与类别输出模块如图 9 所示。首先,通过卷积核大小为 (k_{31}, k_{32}) 的二维卷积对加权后的特征进一步特征提取,从整体上挖掘更深层的特征;其次,接入批量标准化层 (batch normalization, BN)、池化层和 Dropout 层达到提高模型泛化性能、降低参数以及避免模型过拟合的目的;最后,将得出尺寸为 (c_4, h_2, w_2) 的输出特征经

flatten 铺平后使用全连接 (fully connected, FC) 层和 softmax 层输出分类结果 y 。

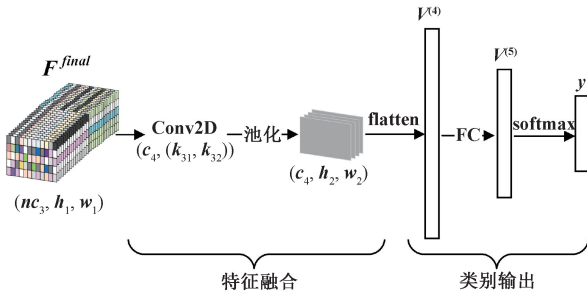


图 9 特征融合与类别输出模块

Fig. 9 Feature fusion and category output module

3 实验分析

从信号选择的角度来看,近年来大多数研究将振动信号应用于轴承故障诊断,并在很多具体问题上取得了显著效果^[21-23]。但是,在特殊环境下许多机械设备不适合安装振动传感器,而利用电流信号检测故障具有非侵入式的优势,在这种情况下可以进行电流信号测量,这使得基于电流信号的故障诊断方法也受到研究人员的关注,例如 Chai 等^[24-25]使用了电流信号做故障检测并取得理想效果。因此,为了验证 MSIFNM 在变工况条件下的诊断性能,本节将利用实验室自测变工况轴承数据集与德国-帕德博恩大学轴承公开数据集分别进行变转速与变负载工况下的多源信息融合故障诊断实验,2 种实验均采用振动信号与电流信号。实验基于 NVIDIA GeForce RTX3090 的 Tensorflow-GPU 环境下加速训练,操作系统为 Windows 10.0。

3.1 变转速条件下的多源信息融合诊断实验

1) 变转速轴承数据集描述

实验台采用 PCB-356A32 三向加速度传感器、Hioki 9660 电流传感器与 ERN180 海德汉旋转编码器等数据进行采集,整个实验台从左到右主要包括驱动电机、扭矩传感器、三向加速度传感器、可替换轴承的轴承座、旋转自编码器和负载系统,如图 10 所示。电流传感器布置在三相异步交流电机的一根输入线上,如图 11 所示。




图 10 轴承数据采集实验台

Fig. 10 Bearing data acquisition test bench



图 11 电流传感器

Fig. 11 Current sensor

实验数据包含 4 种健康状态的振动和电流信号,健康状态分别为滚动体故障、内圈故障、外圈故障和正常。振动信号与电流信号的采样频率均为 20 kHz,电机转速工况为 86、288、576 和 864 rpm,每种工况下不同的轴承健康状态采用不同的标签进行标注,如表 1 所示。

表 1 轴承的 4 类健康状态

Table 1 Four health status of bearing

轴承健康状态	标签
滚动体故障	0
内圈故障	1
外圈故障	2
正常	3

2) 变转速实验结果与分析

该轴承数据集下的振动信号和电流信号分别在转速工况 86、288、576 和 864 rpm 下采集,每种转速工况包含 4 种不同的健康状态。为直观展示振动信号与电流信号,以 86 rpm 工况为例,提取 1 种故障的部分振动和电流信号并绘制时域波形图,如图 12 所示。

首先对原始信号进行降采样,降采样后信号采样频率为 5 kHz。然后对信号进行切片、重叠采样、标签化等数据预处理后构建样本集,单个样本的长度为 5 000 个数据点,各工况下轴承滚动体故障、内圈故障、外圈故障的样本个数均为 592,轴承正常状态下的样本个数为 296,4 种健康状态共 2 072 个样本。数据集在划分训练集与测试集时,选择 3 种转速工况的样本组成训练集,剩余的一种转速工况作为测试集,充当未知工况来对模型进行性能评估,详细的实验任务设置如表 2 所示。

对比实验中的故障诊断模型包括 4 种,分别为:本文所提出的 MSIFNM; MSIFNM-II: 在 MSIFNM 基础上消去多源信息特征加权模块; MSIFNM-III: 在 MSIFNM-II 基础上消去双阶段注意力模块; 普通 CNN 模型。采用试错法选取模型超参数, batch size 取 64, 优化器采用 Adadelta,




图 12 轴承信号的时域波形

Fig. 12 Time domain waveform of bearing data

表 2 4 种变转速实验任务

Table 2 Four experiment tasks of variable speed

任务序号	训练集的转速类别/rpm	训练集样本数	验证集的转速类别/rpm	验证集样本数
A1	288	6 216	86	2 072
	576			
	864			
A2	86	6 216	288	2 072
	576			
	864			
A3	86	6 216	576	2 072
	288			
	864			
A4	86	6 216	864	2 072
	288			
	576			

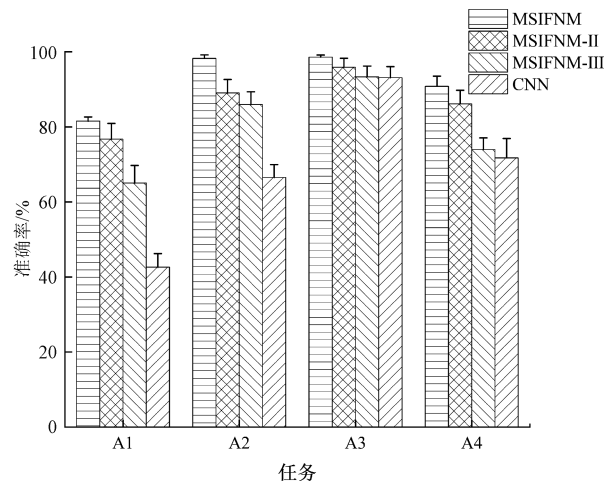


图 13 模型在 4 个任务 (A1~A4) 中的准确率对比

Fig. 13 Comparison of model accuracy in four tasks (A1~A4)

初始学习率为 1.0,学习率衰减值为 0.006,模型共训练 50 epoch。

4 个变工况实验任务的模型性能对比结果如图 13、14 所示。从图 13 中可以看到,MSIFNM 的预测准确率最高、多次实验的准确率标准差最低,并且从图 14 中可以

观察到 MSIFNM 相较于其他 3 个模型具备更优异的收敛性能和诊断稳定性。在 4 个变工况实验任务中,在消去 MSIFNM 结构中的不同关键模块后,准确率均出现下滑现象。例如,在 A1 任务中,与 MSIFNM 相比,MSIFNM-II 去除多源信息特征加权模块后诊断准确率大约下滑 5%,说明加入多源信息特征加权模块后,通过对不同信号源的特征进行加权调制,可以提高模型的诊断准确率。MSIFNM-III 在进一步消去双阶段注意力模块后分类准确

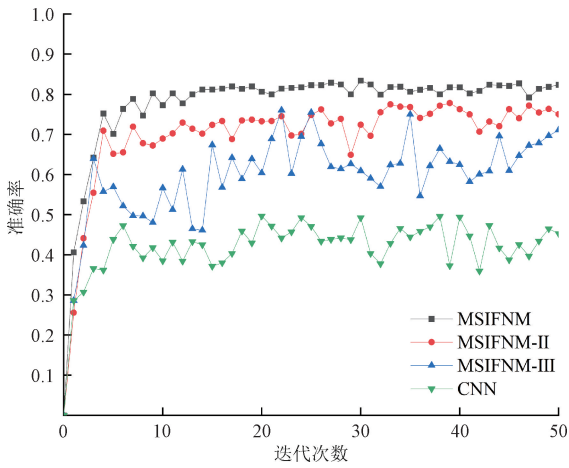


图 14 4 种模型在 A1 任务中的收敛性能

Fig. 14 Convergence performances of four models in the A1 task




图 16 基于不同信号的 MSIFNM 在 A1 任务中的收敛性能

Fig. 16 Convergence performances of the MSIFNM based on different input signals in A1 task

率出现进一步下滑,说明加入双阶段注意力模块后,模型从各个信号源的特征中增强对工况变化不敏感的故障特征,削弱工况的影响,可以提高模型的诊断准确率。当使用普通 CNN 时,准确率大幅度下降至不足 50%,说明使用多尺度 CNN 可以从多个尺度上提取到更全面的故障特征信息,有效提高诊断准确率。此外,MSIFNM 的诊断准确率的误差棒变化最小,说明 MSIFNM 在变工况条件下具有很好的鲁棒性。在其他 3 个实验任务中,MSIFNM 同样表现出最好的诊断性能,说明 MSIFNM 可以实现未知转速工况下的轴承故障诊断。

另一方面,设置模型基于多源信息与单源信息的准确率对比实验,实验结果如图 15、16 所示。在任务 A2 中 MSIFNM 的混淆矩阵如图 17 所示。




图 15 基于不同信号的 MSIFNM 在 4 个任务 (A1~A4) 中的准确率对比

Fig. 15 Accuracy comparison chart of the MSIFNM based on different input signals in four tasks (A1~A4)




图 17 混淆矩阵

Fig. 17 Confusion matrix

从 A1 任务的结果中分析可知,融合振动信号和电流信号的模型对比仅基于振动信号或电流信号的模型,在诊断准确率上分别提高了 15.2% 和 33.1% 左右,且在误差棒的变化上可以观察到,融合振动信号和电流信号的 MSIFNM 具有更好的鲁棒性,说明 MSIFNM 能够从振动信号和电流信号中提取出互补的故障特征,并对不同信号源中提取出的特征进行有效的特征级融合。在其他 3 个实验任务中,融合振动信号和电流信号的模型同样表现出最好的诊断性能。

3) 特征可视化分析

采用 t 分布式随机邻居嵌入算法将 MSIFNM 不同模块的输出特征映射到二维空间,进行特征可视化,如图 18 所示。从图中可以看出,经过多尺度特征提取模块后,4 种健康状态的特征虽然大部分仍然混叠在一起,但是相同健康状态的特征开始出现聚类现象。经过双阶段注意力模块后,4 种健康状态的特征已经各自聚类,且轴承正常状态的特征与滚动体故障的特征已互相分离,证

明了双阶段注意力模块可以增强故障敏感特征。然后,经过多源信息特征加权模块后,外圈故障和内圈故障的特征进一步分离,说明了多源信息特征加权模块可以进一步提取更具有鉴别性的故障特征。最后,经过特征融合与类别输出模块 4 种健康状态的特征互相分离,并进一步将同一种健康状态的特征聚类。

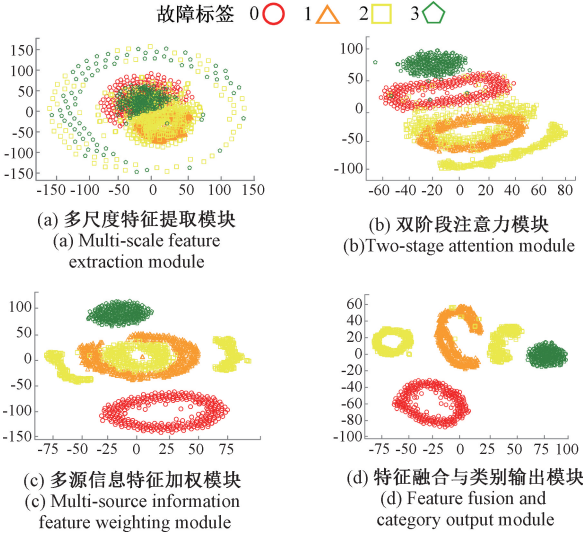


图 18 不同模块输出特征的可视化

Fig. 18 Feature visualization of different modules

4) 权重可视化分析

在轴承的不同健康状态下,对多源信息特征加权模块的权重向量进行可视化,结果如图 19 所示。由图中结果可知:(1)对比同一种健康状态下不同信号源的权重值,多源信息特征加权模块可以根据不同信号源对同一种健康状态的敏感度差异自适应地为不同信号源的特征分配权重;(2)对比同一信号源不同健康状态下的权重值,多源信息特征加权模块可根据同一个信号源对不同健康状态的敏感度差异自适应地调整权重值,证明了多




图 19 不同健康状态下的权重向量可视化

Fig. 19 Weight vector visualization under different health status

源信息特征加权模块的有效性。

3.2 变负载条件下的多源信息融合诊断实验

1) 变负载轴承数据集描述

德国-帕德博恩大学轴承数据采集实验台^[26]如图 20 所示,从左至右依次为:电动机、扭矩测量轴、滚动轴承测试模块、飞轮和负载电动机。电流信号和振动信号的采样频率为 64 kHz。德国-帕德博恩大学数据集由 32 个不同轴承采集的实验数据组成,其中包括 6 个健康轴承、12 个人工损坏轴承和 14 个加速寿命实验导致的真实损坏轴承。为保证实验结果更加真实的反应模型性能,选用基于加速寿命实验的真实损坏轴承数据进行变负载实验。




图 20 轴承数据采集实验台

Fig. 20 Bearing data acquisition experiment bench

本文选取 3 种工况条件下的加速寿命导致的真实损坏轴承数据中的内圈故障、外圈故障和正常轴承组成实验数据集。轴承的健康状态类型详细描述如表 3 所示,工况条件描述如表 4 所示。

表 3 轴承的 3 种健康状态类型

Table 3 Three health status of bearing

轴承健康状态	标签
正常	0
外圈故障	1
内圈故障	2

表 4 3 种工况条件

Table 4 Three operating conditions

转速/rpm	负载扭矩/N·m	径向力/N	设置工况名称
1 500	0.1	1 000	N15_M01_F10
1 500	0.7	400	N15_M07_F04
1 500	0.7	1 000	N15_M07_F10

2) 变负载实验结果与分析

首先,对原始数据进行降采样处理,降采样后的信号采样频率为 8 kHz,然后对信号进行切片、重叠采样、标签化等数据预处理后,构建样本数据集,单个样本长度为 1 600,每种工况下每种健康状态有 1 600 个样本,每种工

况下共有 4 800 个样本中,3 种工况共产生 14 400 个样本。最后,划分训练集和测试集,与变转速实验的设置方法相同,选取 1 种负载工况数据做测试集,其余 2 种负载工况的数据做训练集。变负载实验任务详细描述如表 5 所示。

表 5 3 种变负载实验任务

Table 5 Three experiment tasks under variable load

任务序号	训练集的 负载类别	训练集 样本数	验证集的 负载类别	验证集 样本数
B1	N15_M07_F04	9 600	N15_M01_F10	4 800
	N15_M07_F10			
B2	N15_M01_F10	9 600	N15_M07_F04	4 800
	N15_M07_F10			
B3	N15_M01_F10	9 600	N15_M07_F10	4 800
	N15_M07_F04			

针对 3 个变负载实验任务,对 MSIFNM 模型进行消融对比实验,模型输入信号为振动信号和电流信号,模型在 3 个变负载任务中的轴承故障诊断准确率对比如图 21 所示,实验结果均为 10 次重复实验的平均值。MSIFNM 在 3 个实验任务中均得出最高诊断准确率且多次实验的准确率标准差最低。在任务 B2 中,由于模型训练集只包括径向力 1 000 N 的工况数据,缺乏多样的径向力工况数据,使模型在训练过程中更难提取出对径向力变化不敏感的故障特征,模型没有更好的自适应径向力的变化,进而导致在工况 N15_M07_F04 下准确率偏低,但相较于其他模型,MSIFNM 的诊断效果仍然是最优的。实验结果表明,在变负载条件下 MSIFNM 具备更出色的抗负载变化能力,可以实现未知负载工况条件下的轴承

故障诊断。此外,MSIFNM 的诊断准确率的误差棒变化最小,说明 MSIFNM 在变负载条件下具有很好的鲁棒性。

然后对比基于不同输入信号的 MSIFNM 模型在 3 个变负载任务中的轴承故障诊断准确率,如图 22 所示实验结果均为 10 次重复实验的平均值。从实验结果中可以看出,基于振动信号和电流信号的 MSIFNM 模型故障识别准确率和稳定性最高,仅基于振动信号的 MSIFNM 模型故障识别准确率和稳定性次之,仅基于电流信号的 MSIFNM 模型故障识别准确率和稳定性最差,说明多源信息可以提供更完备的变工况轴承故障信息,有利于提高变工况故障诊断模型的故障识别准确率和稳定性。




图 22 基于不同信号的 MSIFNM 在 3 个任务 (B1~B3) 中的准确率对比

Fig. 22 Accuracy comparison chart of the MSIFNM using different input signals across three tasks (B1~B3)

4 结 论

本文重点研究变工况条件下基于多源信息融合的故障诊断方法,提出了 1 种基于注意力机制的多源信息融合网络模型。本文的结论总结如下:

1) 本文提出的 MSIFNM 一方面通过将多尺度 CNN 与双阶段注意力机制模块相结合,从各个传感器信号中增强对故障类型敏感而对工况变化不敏感的故障特征,另一方面通过多源信息特征加权模块根据不同信号源对不同健康状态的敏感度差异自适应地对多源信息特征进行加权调制,在两方面的共同作用下提高了变工况条件下轴承故障诊断方法的准确性、可靠性和工况自适应性。

2) 分别对 MSIFNM 进行了消融对比实验、基于多源信息与单源信息的对比实验、特征可视化分析和权重向量可视化分析,实验结果证明了多尺度特征提取模块、双阶段注意力模块以及多源信息特征加权模块对提高变工

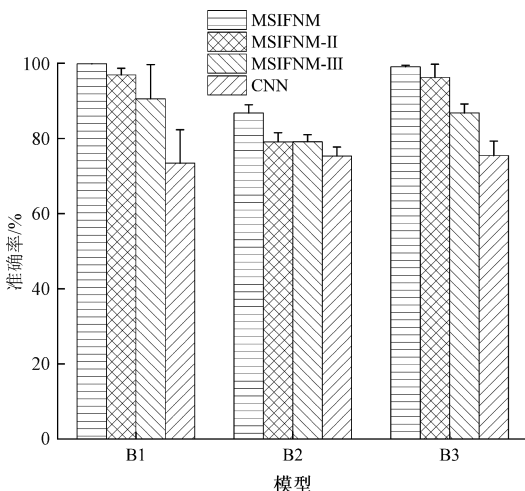


图 21 模型在 3 个任务 (B1~B3) 中的准确率对比

Fig. 21 Comparison of model accuracy in three tasks (B1~B3)

况轴承故障分类准确率和模型稳定性均有积极贡献。MSIFNM 的输入通道可以根据传感器信号数量进行扩展,模型具有普适性。

参考文献

- [1] LI H, LIU T, WU X, et al. Research on bearing fault feature extraction based on singular value decomposition and optimized frequency band entropy [J]. *Mechanical Systems and Signal Processing*, 2019, 118:477-502.
- [2] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. *机械工程学报*, 2018, 54(5): 94-104.
- LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. *Journal of Mechanical Engineering*, 2018, 54(5):94-104.
- [3] 乔卉卉. 基于深度学习的复杂条件下旋转机械健康状态识别与预测[D]. 天津:天津大学机械工程学院, 2020.
- QIAO H H. Identification and prediction of health status of rotating machinery under complex conditions based on deep learning [D]. Tianjin: School of Mechanical Engineering, Tianjin University, 2020.
- [4] LIU D D, CHENG W D, WEN W G. Rolling bearing fault diagnosis via ConceFT-based time-frequency reconfiguration order spectrum analysis [J]. *IEEE Access*, 2018, 6:67131-67143.
- [5] 白云川, 陈成法, 夏均忠, 等. 变转速下滚动轴承故障诊断方法研究现状分析[J]. *军事交通学院学报*, 2019, 21(7):52-56.
- BAI Y CH, CHEN CH F, XIA J ZH, et al. Analysis on the current research status of rolling bearing fault diagnosis methods under variable speed[J]. *Journal of Academy of Military Transportation*, 2019, 21(7): 52-56.
- [6] 王金福, 李富才. 机械故障诊断技术中的信号处理方法: 时频分析[J]. *噪声与振动控制*, 2013, 33(3): 198-202.
- WANG J F, LI F C. Signal processing methods in mechanical fault diagnosis technology: Time-frequency analysis[J]. *Noise and Vibration Control*, 2013, 33(3): 198-202.
- [7] JI M Y, PENG G L, HE J, et al. A two-stage, intelligent bearing-fault-diagnosis method using order-tracking and a one-dimensional convolutional neural network with variable speeds [J]. *Sensors*, 2021, 21(3):21030675.
- [8] LI X, ZHANG W, DING Q. A robust intelligent fault diagnosis method for rolling element bearings based on deep distance metric learning [J]. *Neurocomputing*, 2018, 310(8):77-95.
- [9] QIAO H H, WANG T Y, WANG P, et al. An adaptive weighted multiscale convolutional neural network for rotating machinery fault diagnosis under variable operating conditions[J]. *IEEE Access*, 2019, 7:118954-118964.
- [10] CHEN H P, HU N Q, CHENG ZH, et al. A deep convolutional neural network based fusion method of two-direction vibration signal data for health state identification of planetary gearboxes [J]. *Measurement*, 2019, 146:268-278.
- [11] LI SH, WANG H Q, SONG L Y, et al. An adaptive data fusion strategy for fault diagnosis based on the convolutional neural network [J]. *Measurement*, 2020, 165:108122-108130.
- [12] ZHANG K, GAO T H, SHI H T. Bearing fault diagnosis method based on multi-source heterogeneous information fusion[J]. *Measurement Science and Technology*, 2022, 33(7):075901.
- [13] XIE T L, HUANG X F, CHOI S K. Intelligent mechanical fault diagnosis using multisensor fusion and convolution neural network [J]. *IEEE Transactions on Industrial Informatics*, 2021, 18(5):3213-3223.
- [14] WANG X, MAO D X, LI X D. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network[J]. *Measurement*, 2021, 173:108518.
- [15] DONG Y F, WEN CH B, WANG ZH. A motor bearing fault diagnosis method based on multi-source data and one-dimensional lightweight convolution neural network [C]. *Proceedings of the Institution of Mechanical Engineers, Part I. Journal of Systems and Control Engineering*, 2023, 237(2):272-283.
- [16] LIU M K, TRAN M Q, WENG P Y. Fusion of vibration and current signatures for the fault diagnosis of induction machines[J]. *Shock and Vibration*, 2019, 9:7176482.
- [17] PENG D D, WANG H, DESMET W, et al. RMA-CNN: A residual mixed-domain attention CNN for bearings fault diagnosis and its time-frequency domain interpretability[J]. *Journal of Dynamics, Monitoring and Diagnostics*, 2023, 2:115-132.
- [18] 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):17020425.
- [19] SONG X D, CONG Y Y, SONG Y F, et al. A bearing fault diagnosis model based on CNN with wide convolution kernels [J]. *Journal of Ambient Intelligence and Humanized Computing*, 2021, 13(8):4041-4056.

- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [21] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.
- [22] 康守强, 刘哲, 王玉静, 等. 基于改进 DQN 网络的滚动轴承故障诊断方法[J]. 仪器仪表学报, 2021, 42(3): 201-212.
- KANG SH Q, LIU ZH, WANG Y J, et al. A fault diagnosis method of rolling bearing based on the improved DQN network [J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 201-212.
- [23] 康守强, 杨加伟, 王玉静, 等. 基于联邦多表示域适应的不同工况下滚动轴承故障诊断方法[J]. 仪器仪表学报, 2023, 44(6): 165-176.
- KANG SH Q, YANG J W, WANG Y J, et al. Fault diagnosis method of rolling bearings under different working conditions based on federated multi-representation domain adaptation[J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 165-176.
- [24] CHAI N, YANG M, NI Q N, et al. Gear fault diagnosis based on dual parameter optimized resonance-based sparse signal decomposition of motor current[J]. IEEE Transactions on Industry Applications, 2018, 54(4): 3782-3792.
- [25] CHEN X W, FENG ZH P. Induction motor stator current analysis for planetary gearbox fault diagnosis under time-varying speed conditions [J]. Mechanical Systems and Signal Processing, 2020, 140:106691.
- [26] LESSMEIER C, KIMOTHO J K, ZIMMER D, et al. Condition monitoring of bearing damage in electro-mechanical drive systems by using motor current signals of electric motors; A benchmark data set for data-driven classification [C]. European Conference of the Prognostics and Health Management Society, 2016. DOI:10.36001/PHME.2016.V3I1.1577.

作者简介



乔卉卉, 2013 年于华东交通大学获得学士学位, 2016 年于石家庄铁道大学获得硕士学位, 2020 年于天津大学获得博士学位, 现为石家庄铁道大学讲师、硕士生导师, 主要研究方向为机械故障诊断与寿命预测。

E-mail: Huihuiqiao@stdu.edu.cn

Qiao Huihui received her B.Sc. degree from East China Jiaotong University in 2013, received her M.Sc. degree from Shijiazhuang Tiedao University in 2016, and received her Ph.D. degree from Tianjin University in 2020. She is currently a lecturer and a M.Sc. supervisor at Shijiazhuang Tiedao University. Her research interests include fault diagnosis and remaining useful life prediction of mechanical systems.



郝如江 (通信作者), 1995 年于石家庄铁道大学获得学士学位, 2002 年于郑州大学获得硕士学位, 2008 年于清华大学获得博士学位。现为石家庄铁道大学教授、博士生导师, 研究方向为机械故障诊断与寿命预测。

E-mail: haorj@stdu.edu.cn

Hao Rujiang (Corresponding author) received his B.Sc. degree from Shijiazhuang Tiedao University in 1995, received his M.Sc. degree from Zhengzhou University in 2002, and received his Ph.D. degree from Tsinghua University in 2008. He is currently a professor and a Ph.D. supervisor at Shijiazhuang Tiedao University. His main research interests include fault diagnosis and remaining useful life prediction of mechanical systems.



李东升, 1999 年于石家庄铁道大学获得学士学位, 2012 年于石家庄铁道大学获得硕士学位, 现为中铁十四局集团有限公司正高工, 主要研究方向为机电设备状态监测与故障诊断。

E-mail: 106213516@qq.com

Li Dongsheng received his B.Sc. degree and M.Sc. degree both from Shijiazhuang Tiedao University in 1999 and 2012, respectively. He is currently a senior engineer at China Railway 14th Bureau Group Corporation Limited. His research interests include condition monitoring and fault diagnosis of electro-mechanical equipment.