

文章编号: 2095-2163(2022)09-0037-08

中图分类号: TH165^{*}.3

文献标志码: A

多尺度 CNN 结合自注意力特征融合机制的轴承故障诊断方法

黄雅静¹, 廖爱华¹, 丁亚琦², 杨洋², 师蔚¹, 胡定玉^{1,3}

(1 上海工程技术大学 城市轨道交通学院, 上海 201620; 2 上海地铁维护保障有限公司 车辆分公司, 上海 200235;

3 上海工程技术大学 上海市轨道交通振动与噪声控制技术工程研究中心, 上海 201620)

摘要: 针对轴承故障诊断模型输入信息单一,且变负载、噪声工况下诊断精度受限的问题,提出一种多尺度卷积神经网络结合自注意力特征融合机制(SA-MCNN)的故障诊断方法。该方法首先使用不同核大小的卷积层并行提取振动信号的多尺度信息后,采用自注意力特征融合机制,为并行的多尺度特征加权融合;最后根据融合后的特征,区分轴承的健康状态。实验结果表明,与其它故障诊断模型相比,SA-MCNN模型能够根据多尺度信息有效捕捉高质量的状态特征,在跨负载工况和噪声工况下表现出强鲁棒性。

关键词: 多尺度卷积神经网络; 自注意力机制; 特征融合; 轴承故障诊断

Bearing fault diagnosis based on multi-scale Convolutional Neural Network and self-attention feature fusion mechanism

HUANG Yajing¹, LIAO Aihua¹, DING Yaqi², YANG Yang², SHI Wei¹, HU Dingyu^{1,3}

(1 School of Urban Railway Transportation, Shanghai University of Engineering Science, Shanghai 201620, China;

2 The Vehicle Branch, Shanghai Metro Maintenance Guarantee Co., Ltd., Shanghai 200235, China;

3 Shanghai Engineering Research Center of Vibration and Noise Control Technologies for Rail Transit, Shanghai University of Engineering Science, Shanghai 201620, China)

[Abstract] Considering that the single-source input of bearing fault diagnosis models and poor diagnostic performance under variable load and noise conditions, a new model is proposed by combining the multi-scale Convolutional Neural Network and self-attention feature fusion mechanism (SA-MCNN) for bearing fault diagnosis. In SA-MCNN, the multi-scale information of vibration signals is first extracted by using different convolution kernels in parallel. Then, the multi-scale features are weighted and fused by self-attention feature fusion mechanism. Finally, the health states of bearings are distinguished according to the fused features. The experimental results verify that compared with other fault diagnosis models, the SA-MCNN model can effectively capture high-quality state features based on multi-scale information, and SA-MCNN can stay robust against cross-load or noise conditions.

[Key words] multi-scale Convolutional Neural Network; self-attention mechanism; feature fusion; bearing fault diagnosis

0 引言

在智能制造、工业大数据和工业 4.0 集成创新的推动下,现代工业正在经历一场从传统制造业到智能制造业的新革命,智能故障诊断也随着现代工业的发展而活跃于多个应用领域中^[1]。传统的智能故障诊断方法,如支持向量机(SVM)^[2]、神经网络(MLP)^[3]等,依赖于专业知识和特征选取,且受限于模型浅层结构,已不能满足高精度的现代故障诊断要求。近年来,深度学习^[4]因其强大的深度特征提取能力,为机械智能故障诊断提供了全新的解

决方法。

常见的深度学习方法主要包括:卷积神经网络(CNN)^[5]、自编码器(AE)^[6]、深度置信网络(DBN)^[7]等。各种研究证明,这些深度学习模型在机器健康监测应用中已经获得一定成果。然而,在实际工业环境中,采集到的信号通常包含各种干扰和非平稳状态,使得故障诊断模型难以达到理想的诊断精度。为克服外界干扰,提高非平稳工况下模型的诊断性能,目前基于深度学习的故障诊断方法主要分为增强模型输入和复杂化模型结构两个方向。Cheng 等人^[8]利用局部二进制卷积层代替传统

基金项目: 国家自然科学基金(51605274);上海市地方院校能力建设项目(20030501000)。

作者简介: 黄雅静(1997-),女,硕士研究生,主要研究方向:旋转机械智能故障诊断研究;廖爱华(1978-),女,博士,副教授,主要研究方向:车辆动力学、车辆故障诊断。

通讯作者: 廖爱华 Email: aiwa7816@sues.edu.cn

收稿日期: 2021-11-24

的卷积层,并将连续小波变换频谱图作为输入,提出一种连续小波变换-局部二元卷积神经网络(CWT-LBCNN)的故障诊断模型。Long等人^[9]采用一种基于反向传播神经网络(BPNN)和softmax分类器改进的堆叠式自动编码器(SAE),对一维振动信号进行增强,将增强后的数据集转换成二维灰度图像来训练卷积神经网络(CNN)。Shao等人^[10]提出一种基于集成深度自编码器(EDAEs)的轴承故障诊断方法,使用含不同激活函数的自编码器无监督学习信号特征,并设计联合策略进行特征分类。Zhang等人^[11]提出了一种混合注意力改进的残差网络(HA-ResNet),用于风力发电机齿轮箱故障诊断。HA-ResNet结合通道注意力机制与卷积层改进模型的非线性特征提取能力,在仿真数据和实测数据上都表现出优越的性能。

然而,上述的故障诊断方法大多基于信号处理知识和多种深度学习模型的堆叠。经过信号处理技术后的模型输入实际上带入了先验决策,并且过于复杂的模型堆叠会降低训练速度、耗费大量算力。考虑到振动信号通常表现出的多尺度特性^[12],部分研究人员将其作为一种全新的信号增强方法。Jiang等人^[13]提出一种多尺度卷积网络(MSCNN)的齿轮箱故障诊断方法,以粗粒度信号作为模型的输入,用于提取多尺度特征。Huang等人^[14]提出一种改进的多尺度卷积神经网络(MC-CNN),该网络不仅能自适应地提取故障特征,而且能融合输入信号的多尺度信息,增强对来自不同故障状态的信号的区分能力。上述提及的2种多尺度模型,虽然通过计算信号的粗粒度或是使用不同卷积核大小的卷积层来实现信号增强,均可以提高模型的诊断精度,但随着信号采集过程中不可避免的噪声干扰和负载变化的日益加剧,模型的特征提取能力还有待进一步提高。

近年来,越来越多的研究人员为增强模型特征学习能力而引入注意力机制。朱浩等人^[15]提出一种基于注意力机制和Inception网络结构的卷积神经网络,模型在各种工况下都具有强诊断性能。Li等人^[16]将注意力机制用于轴承智能故障诊断,帮助网络定位输入的信息数据段,并可视化网络学习到的诊断知识。目前,基于自注意力的Transformer^[17]深层神经网络模型在自然语言处理、甚至整个深度学习领域上都迅速全面掀起了新热潮。其中,构成Transformer模型的自注意力机制引起了广泛关注,并且已经成功运用于机器视觉领域^[18]。

考虑到多尺度卷积神经网络在机械故障诊断领

域的成功运用,以及当前自注意力机制的迅猛发展,本文提出一种多尺度卷积神经网络结合自注意力特征融合机制(SA-MCNN)的故障诊断方法。该模型使用核数成倍的卷积层提取信号的多尺度信息,用自注意力机制为多尺度特征加权融合,获得能够分辨故障类型的最终特征。

1 理论背景

1.1 卷积模块

一个卷积模块主要包含卷积层、激活函数和池化层。其中,卷积层由多个卷积核构成,通过窗口滑动的方式计算特征映射。卷积层具有稀疏交互和参数共享的优点,减少了模型参数的数量。卷积层的计算公式为:

$$y_j^{l+1} = \sum_i x_i^l * w_{ij}^l + b_j^{l+1} \quad (1)$$

其中,“*”为卷积操作; x_i^l 为第 l 层第 i 个特征; w_{ij}^l 为第 l 层第 j 个卷积核; b_j^{l+1} 为 l 到 $l+1$ 层的偏置; y_j^{l+1} 为第 $l+1$ 层的第 j 个特征层。

激活函数对卷积层的输出进行非线性转换,常见的激活函数有Sigmoid、ReLU、Tanh等。以ReLU函数为例,经过激活函数的特征为:

$$a_j^{l+1} = \max(0, y_j^{l+1}) \quad (2)$$

池化层通常位于卷积层后,通过下采样的方式过滤掉不重要的特征,降低特征维数并减少网络参数。最常见的池化为最大池化层,选取每个池化块的最大值,即:

$$x_j^{l+1} = \max_S y_j^{l+1} \quad (3)$$

其中, x_j^{l+1} 为 $l+1$ 层第 j 个最终输出特征, S 为池化块的大小。

1.2 自注意力机制

注意力机制是一种将可用计算资源的分配,偏向信号中信息量最大部分的手段^[19]。不仅可以自动选择被关注部分,还可以自适应增强所关注部分。自注意力机制是将单个序列的不同位置相关联的注意力机制,通过关注同一序列中的所有位置,计算序列中每个位置的响应^[20]。自注意力机制的原理如图1所示。

首先,单个样本的 N 个序列 $[x_1, x_2, \dots, x_N]$ 通过自适应线性映射,被转换成3个长度为 d 的向量 $q^i, k^i, v^i (i = 1, \dots, N)$,分别将不同序列的 q^i, k^i, v^i 并联,组合成矩阵 Q, K, V ,根据式(4)计算矩阵 Q, K 的乘积 $S = [S_1, \dots, S_N]$, S 为 N 个序列间的权值集合;再根据式(5)获取标准化后的权值 $S_n =$

$[S_{n_1}, \dots, S_{n_N}]^T$ 。即:

$$S = Q \cdot K^T \quad (4)$$

$$S_n = \frac{S}{\sqrt{d}} \quad (5)$$

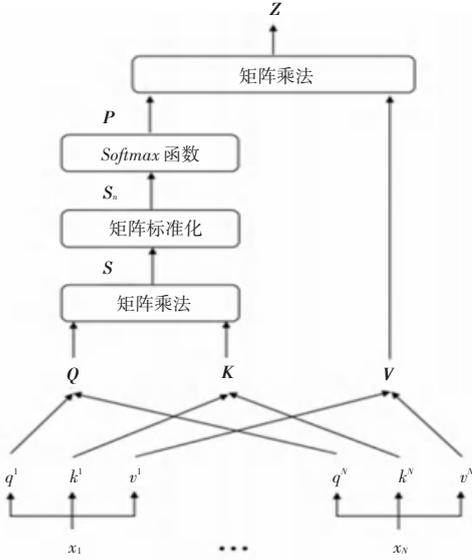


图 1 自注意力机制

Fig. 1 Self-attention mechanism

然后,使用 *Softmax* 函数将权值转换成概率形式 $P = [P_1, \dots, P_N]$, 其公式分别见式(6)、式(7):

$$P_i = \text{Softmax}(S_n) = \frac{e^{S_{ni}}}{\sum_{i=1}^N e^{S_{ni}}} \quad (6)$$

$$P_i = \frac{e^{S_{ni}}}{\sum e^{S_{ni}}} \quad (7)$$

最后根据式(8)获取加权矩阵 Z :

$$Z = V \cdot P \quad (8)$$

整个自注意力过程见式(9):

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{Q \cdot K^T}{\sqrt{d}}\right) \cdot V \quad (9)$$

2 基于 SA-MCNN 的诊断方法

考虑到振动信号的多尺度特性,将本文提出的 SA-MCNN 网络用于轴承故障诊断。SA-MCNN 模型结构如图 2 所示。其中包含多尺度特征学习、多尺度特征融合和分类三部分。对此拟做研究分述如下。

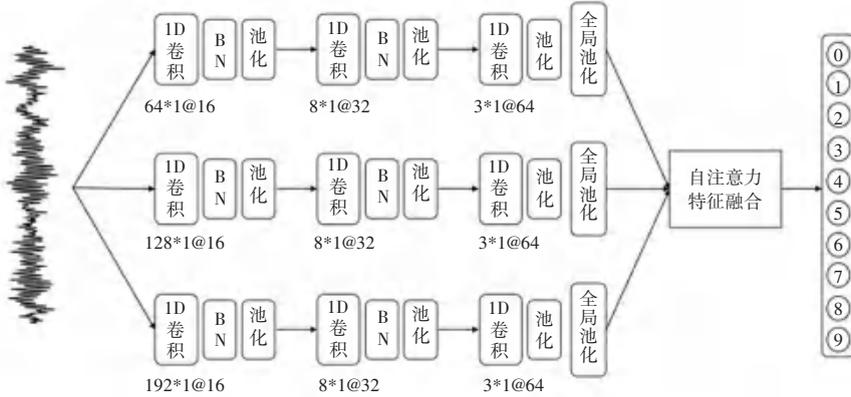


图 2 SA-MCNN 网络框架

Fig. 2 The architecture of the proposed SA-MCNN

2.1 多尺度特征提取和学习

不同核大小的卷积层具有不同的频率分辨率, SA-MCNN 模型的多尺度信号提取过程依赖于核数成倍的卷积层。在 SA-MCNN 中,第一层均使用核数较大的卷积层,提取信号不同时间尺度的信息;然后以并行方式,学习不同时间尺度上的有用故障特征。随着网络加深,卷积层的核数不断减小、而通道数增多,能够获得包含更丰富和互补诊断信息的多尺度特征。由图 2 可知,SA-MCNN 的卷积模块中加入了批量归一化(BN)层,且网络分支的末端加入了全局平均池化(GAP)层。BN 层在整个训练过程

中实现激活值的稳定分布,提高网络的特征学习能力和泛化能力,GAP 层汇总了空间信息,降低最后输出特征的维度,有效防止网络过拟合发生。

2.2 多尺度特征融合机制

多尺度特征提取后,如何融合多尺度特征,使得各个尺度信息互补,对于后续故障类型识别至关重要。常见的方法为各个尺度特征串联,再通过全连接层分类^[13-14]。然而不同尺度特征的重要程度不同,甚至同一尺度特征间各个特征值的重要程度也不相同。

考虑到自注意力机制能够计算同一序列不同位

置响应的特性,本文提出一种基于自注意力的特征融合机制。多尺度特征融合过程如图3所示。

首先,将不同尺度的特征重新并联构成一个新的特征矩阵 $F = [f_1, f_2, \dots, f_N]$, 然后分别经过3个全连接层获得 $Q = [q_1, q_2, \dots, q_N]$ 、 $K = [k_1, k_2, \dots, k_N]$ 和 $V = [v_1, v_2, \dots, v_N]$ 三个维度相同的矩阵,并根据式(4)~(6)计算特征的权重系数;根据式(7)计算加权矩阵,并经过全连接层获得带权重的多尺度特征矩阵 $F' = [f'_1, f'_2, \dots, f'_N]$;最后,将加权

后的各尺度特征求和,获取最终的深度特征 $\hat{F} = \sum_{n=1}^N f'_n$ 。

基于自注意力的特征融合机制,能够考虑每个尺度特征的每个特征值与其它各特征值间的关系,自适应地为不同尺度特征赋予权重,实现特征跨通道、跨位置的交互。特征融合机制能够充分利用特征互补特性,获取含有分类信息的特征,提高模型的诊断精度。

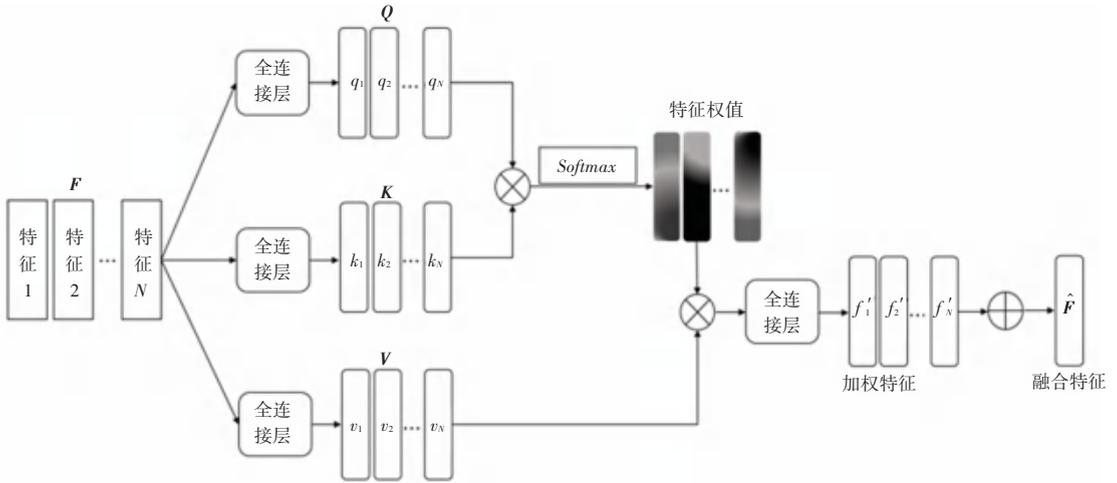


图3 自注意力多尺度特征融合机制

Fig. 3 Self-attention multi-scale feature fusion mechanism

2.3 基于 SA-MCNN 的故障诊断流程

基于 SA-MCNN 的轴承故障诊断流程如图4所示,其故障诊断步骤如下:

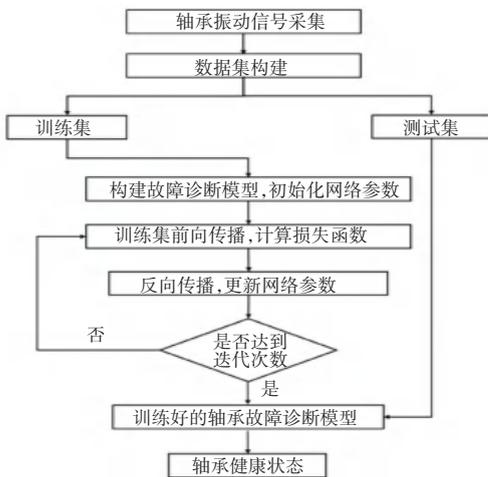


图4 基于 SA-MCNN 的轴承故障诊断流程

Fig. 4 Flow chart of bearing fault diagnosis based on SA-MCNN

步骤1 使用传感器采集不同工况、不同健康状态下的轴承振动信号,将信号截断成单个样本并打上标签。

步骤2 带有标签的样本被随机分成训练集和测试集。训练集用于训练 SA-MCNN 网络,模型的损失函数通过梯度反向传播优化模型参数,经过多次迭代后模型训练完毕。

步骤3 将测试集代入训练好的 SA-MCNN 模型中,预测未知轴承的健康状态,并通过已知标签计算诊断精度,验证模型的有效性。

3 实验与分析

3.1 实验数据描述

本文使用美国凯斯西储大学轴承数据集^[21]验证 SA-MCNN 模型性能。验证对象为驱动端的轴承振动数据,轴承型号为 SKF6205,采样频率为 12 kHz。实验数据包含 3 种不同负载工况,轴承健康状态共有 10 类。其中,电火花加工不同故障程度的轴承内圈、外圈以及滚动体的单点故障,故障大小为 7 mils、14 mils 和 21 mils,分别对应故障直径 0.177 8 mm、0.355 6 mm 和 0.533 4 mm。

考虑到轴承转速和采样频率,为使样本包含轴承旋转一周以上的信息,本文选取 1 024 个点为一

个输入样本。由于故障信号的长度有限,为获取足够的样本个数,使用滑动重叠采样方法,针对每一故障轴承,分别独立获取训练样本 500 个,测试样本 100 个。信号滑动重叠采样方法示意如图 5 所示。根据负载工况的不同,分别构建数据集 A、B、C,各轴承数据集的描述详见表 1。以数据集 A 为例,由负载为 1 马力的轴承训练集和测试集组成。

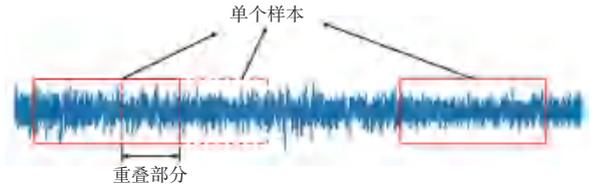


图 5 信号滑动重叠采样方法

Fig. 5 Signal sliding overlap sampling method

表 1 轴承数据集描述

Tab. 1 The description of bearing dataset

轴承健康状态	故障大小/mils	标签	数据集 A			数据集 B			数据集 C		
			训练集	测试集	负载/马力	训练集	测试集	负载/马力	训练集	测试集	负载/马力
正常	0	0	500	100	1	500	100	2	500	100	3
内圈故障	7	1	500	100	1	500	100	2	500	100	3
	14	2	500	100	1	500	100	2	500	100	3
	21	3	500	100	1	500	100	2	500	100	3
滚动体故障	7	4	500	100	1	500	100	2	500	100	3
	14	5	500	100	1	500	100	2	500	100	3
	21	6	500	100	1	500	100	2	500	100	3
外圈故障@ 6:00	7	7	500	100	1	500	100	2	500	100	3
	14	8	500	100	1	500	100	2	500	100	3
	21	9	500	100	1	500	100	2	500	100	3

3.2 模型参数选择

SA-MCNN 的模型(见图 2)具有不同尺度大小的分支,为获取最好的模型性能和节省计算成本,本节讨论模型的尺度大小和模型深度对诊断精度的影响。整个研究过程基于数据集 A,批量大小为 50,学习率为 0.002。

3.2.1 模型尺度大小影响

振动信号通常表现出多尺度特性,在 SA-MCNN 中利用不同核大小的卷积层,提取轴承信号的多尺度信息。尺度个数的增多为模型带来更丰富信息的同时,也会增大网络的复杂程度和训练难度,造成不必要的计算损失。本文选择固定模型深度为 2 层,仅对 1~4 个尺度对模型性能影响进行研究。其中,卷积核大小为 64 及其倍数。不同尺度大小的模型诊断精度和训练时间如图 6 所示。

由图 6 可知,随着信号尺度的增多,网络的诊断精度不断提高,但训练时间也在快速增加。比较单尺度和多尺度的诊断精度可见,多尺度网络明显优于传统的卷积网络。当尺度大小为 3 时,模型的诊断精度达到最高,且训练时长居中。

3.2.2 模型深度大小影响

随着故障诊断模型的加深、卷积模块的增多,所提取的特征更加可分。但是模型加深必然造成模型复杂化,且容易导致过拟合。本文在尺度为 3 的基础上,讨论了 1~3 层模型深度对模型性能的影响。不同深度的模型诊断精度和训练时间如图 7 所示。当模型深度为 3 时,可以达到 100% 的诊断精度。

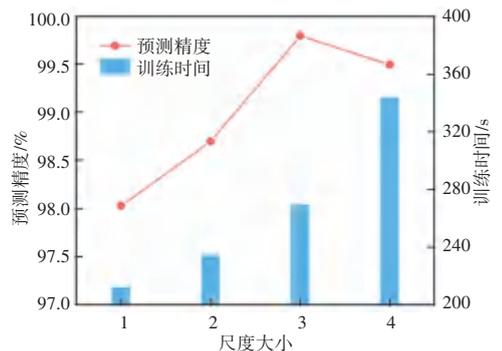


图 6 不同信号尺度个数下的诊断精度和训练时间对比

Fig. 6 Comparison of prediction accuracy and training time under different signal scales

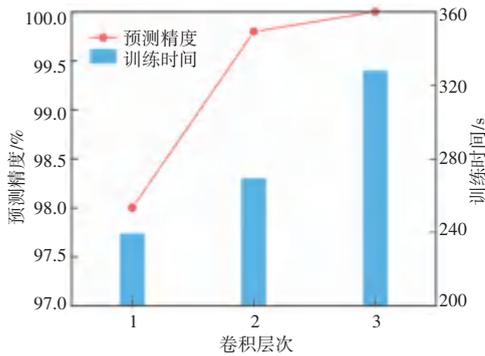


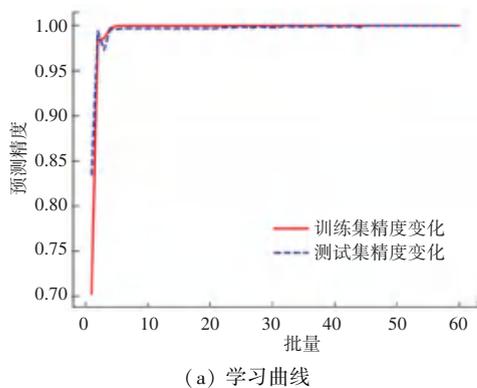
图7 不同卷积层数下的诊断精度和训练时间对比

Fig. 7 Comparison of prediction accuracy and training time under different number of convolutional layers

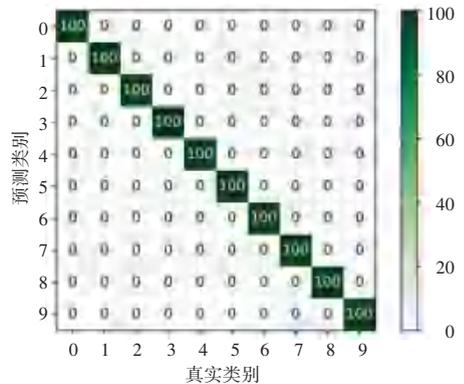
3.3 SA-MCNN 模型性能验证

3.3.1 稳态条件下的模型性能

基于上述模型参数分析,最终确定 SA-MCNN 模型框架的尺度为 3、深度为 3。详细的 SA-MCNN 模型参数详见图 2 和表 2。以数据集 A 为例,整个模型训练过程的学习曲线和混淆矩阵如图 8 所示。由图 8 可见,模型具有很好的性能表现,没有出现过



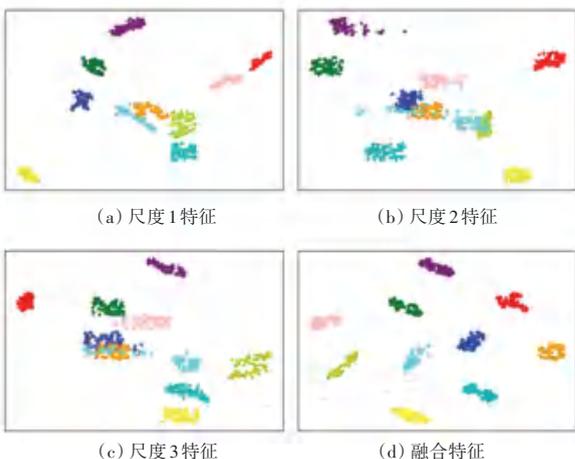
(a) 学习曲线



(b) 测试集混淆矩阵

图8 SA-MCNN 的学习曲线和混淆矩阵

Fig. 8 The learning curve and confusion matrix of SA-MCNN model



(c) 尺度 3 特征

(d) 融合特征

图9 SA-MCNN 多尺度特征分布可视化

Fig. 9 The multi-scale feature distribution visualization of SA-MCNN

拟合。此外,为证明自注意力特征融合机制的优越性,使用 t-SEN^[22] 方法,可视化 3 个尺度的特征和融合后的特征。图 9 为单一尺度特征分布。由图 9 可以看出大部分不同类别的信号特征分布重叠混乱,使得模型难以诊断信号类别。而在图 9(d)中,融合后的信号特征由于自注意力机制自适应为不同尺度特征加权,增强与故障类别相关的信号同时抑制干扰特征,使得不同类别的信号特征完全可分。

表2 SA-MCNN 模型参数

Tab. 2 Parameters of SA-MCNN

编号	尺度 1	尺度 2	尺度 3
1	卷积(64×1@16)	卷积(128×1@16)	卷积(192×1@16)
2	最大池化(2)	最大池化(2)	最大池化(2)
3	卷积(8×1@32)	卷积(8×1@32)	卷积(8×1@32)
4	最大池化(2)	最大池化(2)	最大池化(2)
5	卷积(3×1@64)	卷积(3×1@64)	卷积(3×1@64)
6	最大池化(2)	最大池化(2)	最大池化(2)
7	全连接层(64,10)	全连接层(64,10)	全连接层(64,10)

3.3.2 跨负载工况下的性能分析

在实际工业环境中,工作负载会根据生产需求而不定时变化,因此采集到的数据样本通常具有非稳态特性。本节主要研究 SA-MCNN 模型对于可变负载的适应能力,并同时与 MCNN、MSCNN^[13]、MC-CNN^[14]、CNN 这 4 种模型进行对比。MCNN 为 SA-MCNN 模型不添加自注意力特征融合机制,直接将并行学习到的多尺度特征串联,并与全连接层相接判断信号类别。MSCNN 和 MC-CNN 为 2 种不同的多尺度卷积神经网络。其中,MSCNN 使用不同尺度的粗粒度信号并行学习多尺度特征,MC-CNN 则使用不同核大小卷积层串联学习多尺度特征。CNN 为不包含 GAP 层的 SA-MCNN 模型的第一个分支。表 3 中描述了 4 种跨负载工况。以工况 A₁ 为例,表

1 中的数据集合 B 、 C 构成训练集,数据集 A 构成测试集,用于验证经 B 、 C 数据集训练后的模型在数据集 A 上的泛化性能。每一种工况下训练集样本为 12 000 个,测试集样本 6 000 个。数据集 A_4 为 3 种负载的混合状态,训练样本 15 000 个,测试样本 3 000 个。跨负载工况下,不同模型的诊断精度见表 4。

表 3 跨负载数据集

Tab. 3 The dataset description under cross-domain variable load

	A_1	A_2	A_3	A_4
训练集	数据集 B 、 C	数据集 A 、 C	数据集 A 、 B	测试集 A 、 B 、 C
测试集	数据集 A	数据集 B	数据集 C	训练集 A 、 B 、 C

表 4 跨负载工况下 5 种模型诊断精度

Tab. 4 The diagnostic accuracy of 5 models under cross-domain variable load

模型	A_1	A_2	A_3	平均
SA-MCNN	98.15	99.12	99.58	98.95
MCNN	94.05	98.13	97.24	96.47
MSCNN ^[13]	94.00	97.03	97.51	96.06
MC-CNN ^[14]	96.23	95.57	98.10	96.68
CNN	92.70	95.40	96.00	94.70

在 A_1 、 A_2 、 A_3 三个跨负载工况下,多尺度卷积模型的诊断精度明显高于传统 CNN,表明多尺度特征学习能够增强模型的输入信息,提高模型的诊断性能。而在 4 种多尺度模型中,SA-MCNN 模型的平均诊断精度达到 98.95%,较 MCNN、MSCNN、MC-CNN 三种模型分别提高了 2.48%、2.89%、2.27%。说明 SA-MCNN 模型在跨负载工况下表现出强鲁棒性,具有很强的模型泛化能力。同时,对比 SA-MCNN 和 MCNN 的诊断精度,进一步证明了自注意力特征融合机制的优越性。

3.3.3 负载变化工况下抗噪性能分析

轴承的工作环境复杂,通常同时伴随负载变化和强噪声污染问题。选择表 3 中 A_4 数据集,模拟变负载工况, A_4 的训练集用于训练模型,验证 SA-MCNN、MCNN、MSCNN、MC-CNN、CNN 这 5 种模型在变负载工况下的抗噪性能。在 A_4 的测试集中加入高斯白噪声获得信噪比为 -4 dB 至 10 dB 的复合信号,模拟实际噪声环境中采集到的轴承信号,用于检测训练后的模型精度。以获取信噪比为 -4 dB 的复合信号为例,获取复合信号的过程如图 10 所示。由图 10 可以看出,原始信号的周期性冲击被明显掩盖,这将不利于后续的故障诊断。不同信噪比下模型的诊断精度如图 11 所示。

图 11 中,SA-MCNN 在不同信噪比下的平均诊断精度达到 95.41%,抗噪性能明显优于其它模型。当信噪比为 -4 dB 时,SA-MCNN 模型的诊断精度为 83.07%,约高于其它模型 10%。此时,3 种多尺度模型 MCNN、MSCNN、MC-CNN 的诊断精度较传统 CNN 模型相差较小,可能是由于多尺度模型在增加多尺度信息的同时,也会增多噪声,导致模型诊断精度无法明显提高。但是,SA-MCNN 由于自注意力特征融合机制的加入,模型能够自适应融合并增强有效特征,从而使得诊断精度有明显提高。随着信噪比的不断增加,模型的诊断精度均不断增大,且多尺度模型的诊断精度明显高于传统 CNN。当信噪比大于 6 dB 时,SA-MCNN 的诊断精度达到 100%。比较 MCNN 和 SA-MCNN 的诊断精度,可以看出,自注意力特征融合机制的加入能够明显增强模型的抗噪性能。实验结果表明,SA-MCNN 在负载变化和噪声环境的同时作用下,依然具有较强的泛化能力和抗干扰能力。

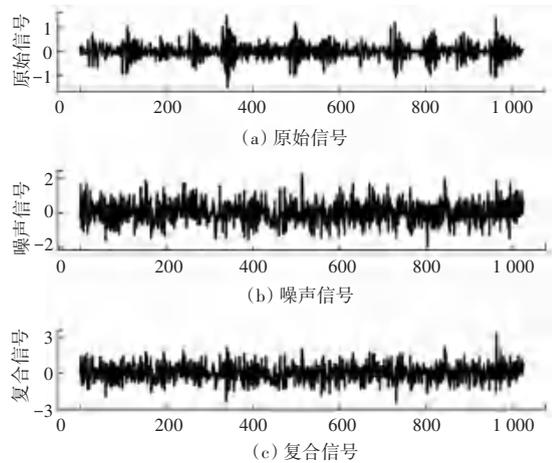


图 10 原始信号、噪声信号及信噪比为 -4 dB 的复合信号
Fig. 10 Original signal, noise signal and composite signal with a SNR of -4 dB

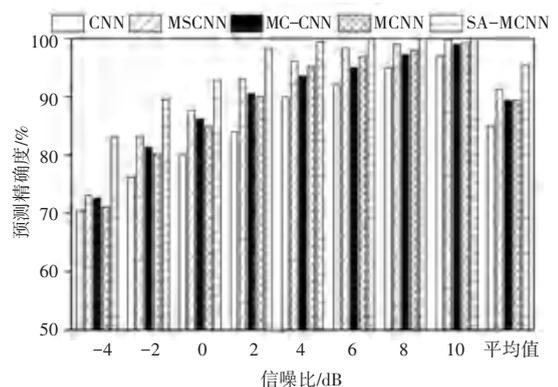


图 11 负载变化时不同信噪比下模型的诊断精度
Fig. 11 The diagnostic accuracy of 5 models under different SNRs with the changing loads

4 结束语

本文结合多尺度卷积神经网络和自注意力特征融合机制提出一种轴承故障诊断方法 SA-MCNN, 经验证得出如下结论:

(1) 在稳态工况下, SA-MCNN 模型能够达到 100% 的诊断精度。经 t-SEN 方法可视化的特征分布表明, 多尺度卷积神经网络和自注意力特征融合机制的结合可以在不同尺度上捕获互补和丰富的诊断信息, 极大提高了模型特征学习能力和诊断精度。

(2) 对比其它多尺度模型, SA-MCNN 在跨负载和噪声工况下表现出明显优势。在跨负载工况下, 模型的平均诊断精度为 98.95%, 具有强鲁棒性。在负载变化的噪声工况下, 模型的诊断精度始终高于其它方法, 平均诊断精度达到 95.14%, 具有较强的抗干扰能力。

参考文献

- [1] JIAO Jinyang, ZHAO Ming, LIN Jing, et al. A comprehensive review on convolutional neural network in machine fault diagnosis [J]. *Neurocomputing*, 2020, 417:36-63.
- [2] 葛江华, 刘奇, 王亚萍, 等. 支持张量机与 KNN-AMDM 决策融合的齿轮箱故障诊断方法 [J]. *振动工程学报*, 2018, 31(06):1093-1101.
- [3] UNAL M, ONAT M, DEMETGUL M, et al. Fault diagnosis of rolling bearings using a genetic algorithm optimized neural network [J]. *Measurement*, 2014, 58:187-196.
- [4] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. *Science*, 2006, 313:504-507.
- [5] JANSSENS O, SLAVKOVIKJA V, VERVISCH B, et al. Convolutional Neural Network based fault detection for rotating machinery [J]. *Journal of Sound and Vibration*, 2016, 377:331-345.
- [6] ZHANG Wei, LI Chuanhao, PENG Gaoliang, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. *Mechanical Systems and Signal Processing*, 2018, 100:439-453.
- [7] SHANG Zhiwu, LIAO Xiangxiang, GENG Rui, et al. Fault diagnosis method of rolling bearing based on deep belief network [J]. *Journal of Mechanical Science and Technology*, 2018, 32(11):5139-5145.
- [8] CHENG Yiwei, LIN Manxi, WU Jun, et al. Intelligent fault diagnosis of rotating machinery based on continuous wavelet transform - local binary convolutional neural network [J]. *Knowledge-Based Systems*, 2021, 216:106796.
- [9] LONG Yunyao, ZHOU Wuneng, LUO Yong. A fault diagnosis method based on one - dimensional data enhancement and convolutional neural network [J]. *Measurement*, 2021, 180:109532.
- [10] SHAO Haidong, JIANG Hongkai, LIN Ying, et al. A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders [J]. *Mechanical Systems and Signal Processing*, 2018, 102:278-297.
- [11] ZHANG Kai, TANG Baoping, DENG Lei, et al. A hybrid attention improved ResNet based fault diagnosis method of wind turbines gearbox [J]. *Measurement*, 2021, 179(10):109491.
- [12] ZHANG Long, XIONG Guoliang, LIU Hesheng, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference [J]. *Expert Systems with Applications*, 2010, 37(8):6077-6085.
- [13] JIANG Guoqian, HE Haibo, YAN Jun, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox [J]. *IEEE Transactions on Industrial Electronics*, 2018, 66(4):3196-3207.
- [14] HUANG Weiyi, CHENG Junsheng, YANG Yu, et al. An improved deep convolutional neural network with multi - scale information for bearing fault diagnosis [J]. *Neurocomputing*, 2019, 359:77-92.
- [15] 朱浩, 宁芊, 雷印杰, 等. 基于注意力机制-Inception-CNN 模型的滚动轴承故障分类 [J]. *振动与冲击*, 2020, 39(19):85-93.
- [16] LI Xiang, ZHANG Wei, DING Qian. Understanding and improving deep learning-based rolling bearing fault diagnosis with attention mechanism [J]. *Signal Processing*, 2019, 161:136-154.
- [17] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS '17). Long Beach, California, USA: NIPS Foundation, 2017:6000-6010.
- [18] DOSOVITSKIY A, BEYER L, KOLESNIKOV A, et al. An image is worth 16×16 words: Transformers for image recognition at scale [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020:1-21.
- [19] HU Jie, SHEN Li, SUN Gang. Squeeze-and-excitation networks [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, UT, USA: IEEE, 2018:7132-7141.
- [20] HAN Kai, WANG Yunhe, CHEN Haiting, et al. A survey on visual transformer [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2021:1-23.
- [21] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the case western reserve university data: A benchmark study [J]. *Mechanical Systems and Signal Processing*, 2015, 64-65:100-131.
- [22] LIN Min, CHEM Qiang, YAN Shuicheng. Network in network [C] // 2nd International Conference on Learning Representations (ICLR 2014). Banff, AB, Canada: dblp, 2014, 1-10.