

基于多分支稀疏残差网络的轴承故障诊断方法

赵学义¹, 张晓光^{2,3,4}, 陆凡凡⁵, 周立⁵, 徐清晨⁵

1. 安徽海螺水泥股份有限公司, 安徽 芜湖 241000
2. 上海智质科技有限公司, 上海 201801
3. 中国科学技术大学 计算机科学与技术学院, 合肥 230026
4. 长三角信息智能创新研究院, 安徽 芜湖 241000
5. 安徽智质工程技术有限公司, 安徽 芜湖 241000

摘要:目的 工业生产中,滚动轴承运行环境复杂,环境噪声降低了常见网络模型对轴承故障识别的准确率,抗噪声干扰能力低,为了提高模型识别准确率与抗噪声干扰能力,设计了多分支稀疏残差网络对轴承故障进行诊断。方法 多分支稀疏残差网络采用多分支结构,分别采用不同卷积核对不同窗口大小的特征进行多尺度特征融合以提高网络模型的识别准确率与抗噪声干扰能力;此外,将注意力机制融入多分支网络中,对各个分支卷积层的权重进行调整;最后,为了提高所提方法的特征学习能力,引入稀疏残差连接,避免数据冗余。结果 通过对比实验,验证了所提方法的有效性,处于无噪声情况下,识别准确率达 99.2%,处于强噪声情况下,模型识别准确率达 95.85%,在实际生产场景中模型的识别率为 98.90%。结论 实验结果表明:该模型有着很强的特征学习能力,轴承故障识别精度较高,有着较强的抗噪声干扰能力,有着较好的实用价值。

关键词:多分支;稀疏残差;故障诊断;多尺度特征融合

中图分类号:TH133.33;TP277 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2025.0006.007

Bearing Fault Diagnosis Method Based on Multi-branch Sparse Residual Network

ZHAO Xueyi¹, ZHANG Xiaoguang^{2,3,4}, LU Fanfan⁵, ZHOU Li⁵, XU Qingchen⁵

1. Anhui Conch Cement Co., Ltd., Wuhu 241000, Anhui, China
2. Shanghai Zhizhi Technology Co., Ltd., Shanghai 201801, China
3. School of Computer Science and Technology, University of Science and Technology of China, Hefei 230026, China
4. Yangtze River Delta Information Intelligence Innovation Research Institute, Wuhu 241000, Anhui, China
5. Anhui Zhizhi Engineering Technology Co., Ltd., Wuhu 241000, Anhui, China

Abstract: Objective In industrial production, the operating environment of rolling bearings is complex, and environmental noise reduces the accuracy of common network models for bearing fault identification, leading to low noise interference resistance. To improve model identification accuracy and noise interference resistance, a multi-branch sparse residual network was designed for bearing fault diagnosis. **Methods** The multi-branch sparse residual network utilized a multi-branch structure, employing different convolution kernels to perform multi-scale feature fusion on features of varying

收稿日期:2024-02-04 **修回日期:**2024-04-22 **文章编号:**1672-058X(2025)06-0048-07

基金项目:国网辽宁省电力有限公司科技项目(2023YF-21)。

作者简介:赵学义(1987—),男,安徽阜阳人,工程师,从事故障诊断、设备管理研究。

通信作者:陆凡凡(1997—),女,安徽合肥人,硕士研究生,从事模式识别、故障诊断研究。Email: lff666abc@126.com.

引用格式:赵学义,张晓光,陆凡凡,等.基于多分支稀疏残差网络的轴承故障诊断方法[J].重庆工商大学学报(自然科学版),2025,42(6):48-54.

ZHAO Xueyi, ZHANG Xiaoguang, LU Fanfan, et al. Bearing fault diagnosis method based on multi-branch sparse residual network[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(6): 48-54.

window sizes, thereby enhancing the model's identification accuracy and resistance to noise interference. Additionally, an attention mechanism was integrated into the multi-branch network to adjust the weights of the convolutional layers in each branch. Finally, to improve the feature learning capability of the proposed method, sparse residual connections were introduced to avoid data redundancy. **Results** Through comparative experiments, the effectiveness of the proposed method was verified, achieving an identification accuracy of 99.2% under noise-free conditions and an identification accuracy of 95.85% under strong noise conditions. In actual production scenarios, the model's recognition rate was 98.90%. **Conclusion** The experimental results indicate that the model has strong feature learning capability. It achieves high accuracy in bearing fault identification, demonstrates strong resistance to noise interference, and possesses significant practical value.

Keywords: multi-branch; sparse residual; fault diagnosis; multi-scale feature fusion

1 引言

现代工业各个领域中,旋转机械起着重要的作用,发生故障时会极大降低工业生产效率,甚至危及工人的人身安全^[1]。为保证安全生产,需对旋转机械进行监测。旋转机械上大量使用滚动轴承,工作环境复杂,保障滚动轴承无故障运行是工业高效率生产的前提。

深度学习算法模型逐步与故障诊断相结合^[2]。旋转设备运行时产生大量的振动数据,深度学习可以从海量数据中提取特征,从历史数据中学习重要性较强的高维度数据,降低了对专家经验的依赖程度。深度信念网络(Deep Belief Network, DBN)^[3]、自编码器网络(Auto-Encoder, AE)^[4]、卷积神经网络(Convolutional Neural Network, CNN)等^[5-6]已深度应用于各垂直领域。

使用 CNN 框架搭建的模型广泛应用于轴承故障诊断^[7-9]。工业提取的振动信号通常具有多尺度特性^[10],大多数研究人员采用不同大小的卷积核进行轴承振动信号多分支故障特征识别。Jiang 等^[11]设计的多尺度卷积网络(Multi-Scale Convolutional Neural Network, MSCNN)用于齿轮箱故障诊断,效果良好;Huang 等^[12]搭建多分支卷积神经网络(Multi-Branch Convolutional Neural Network, MBCNN),MBCNN 处理多尺度信号时表现优异。

神经网络层数越深,信号特征提取能力越强,但是 CNN 的网络层数过深时,性能会随着层数的增加而下降。残差网络与短连接结构相融合,可以加速网络模型中的信息处理速度,有效抑制网络退化。赵小强等^[13]使用残差学习改善了 CNN 的训练性能,采用空洞卷积和改进的残差结构提升了模型的鲁棒性;Wen

等^[14]将 ResNet-50 与 TCNN 相结合构建了一种新的 TCNN 网络模型,用于轴承故障诊断。


大多数诊断模型仅将单支信号输入浅层网络进行特征提取。由于轴承工作环境复杂,故障特征分布在不同特征区间、不同分支内,使得振动数据关键故障特征提取困难。

为了解决上述问题,网络采取多分支策略,并引入稀疏残差网络与空间注意力进行轴承故障诊断。将单输入信号划分为多个分支信号,每个分支信号尺度大小都不相同,同时为每个分支信号分配相应的卷积层进行特征提取;然后,将完整的振动信号进行拆分,输入各分支网络模型提取特征,再将所有分支的特征数据进行融合;最后,实验结果和工程验证均表明:该模型具有较强的特征学习能力,在轴承故障诊断中具有较高的故障诊断精度。


2 基础理论

2.1 残差网络

CNN 是前馈神经网络^[15],层与层之间直接相连,可以实现权重共享,由卷积层、池化层堆叠而成,CNN 搭建的网络层数较深,易出现过拟合,可以引入残差结构来解决(图 1)。



(a) 两层残差结构



(b) 三层残差结构

图 1 残差结构图

Fig. 1 Diagram of the residual structure

图 1 描述了公共残差模块,当网络输入 X 和 F 具有相同维度时,残差模块定义如下:

$$y = F(X, \{\omega_i\}) + X \quad (1)$$

式(1)中, $F(X, \{\omega_i\})$ 代表残差映射,对应于图 1(a) 中的两个卷积层或图 1(b) 中的 3 个卷积层。

当网络输入 X 和 F 具有不同维度时,可以为网络增加线性映射 W_s ,通过短连接匹配不同的维度,式(2)用来描述残差块:

$$y = F(X, \{\omega_i\}) + W_s X \quad (2)$$

从残差模块的输入到输出的恒定映射路径称为短连接结构。短连接结构保留了输入中包含的特征信息,减轻了特征信息在前向传播期间的衰减。图 1(a) 残差块在浅层网络中表现较好。当网络更深时,图 1(b) 中的残差块可以提高训练速度。

2.2 多尺度卷积神经网络

多尺度卷积神经网络 (Multi-scale Convolutional Neural Networks, MSCNN) 属于深度神经网络,全卷积网络 (Fully Convolutional Networks, FCN)^[16] 与 GoogleNet^[17] 都属于深度网络模型。MSCNN 的核心思想是通过多个卷积层学习输入信号的长期特征和短期特征^[18]。不同大小的多个卷积层通常并行排列,它们被称为多尺度卷积层。多尺度卷积层的输入是唯一的。首先,输入的数据通过特征提取模块,然后提取的特征通过逐元素求和融合成一个输出。多尺度卷积层结构如图 2 所示。

在图 2 中, a_i 表示第 i 层卷积核大小, $\text{Conv}(a_i)$ 表示第 i 层的卷积操作,共有 n 层卷积操作。输入特征经过卷积层 ($\text{Conv}(a_i)$)、批量归一化 (BN)、激活函数 (ReLU),计算出第 i 层的高维度特征 o_i 。




图 2 多分支结构图

Fig. 2 Diagram of multi-branch structure

2.3 注意力机制

残差网络在提取数据关键性特征以及促进网络信息传播方面是有效的,但是提取的特征信息有可能相互促进,也有可能相互矛盾,导致模型的错误判断。可以将注意力机制 (Convolutional Block Attention Module, CBAM) 与 ResNet 相互融合解决上述问题。CBAM 又分为通道注意力模块 (Channel Attention Module, CAM) 与空间注意力模块 (Spatial Attention Module, SAM),两个模块分别在通道层面与空间层面上进行注意力识别,两者相互配合自动学习数据在通道和空间之间的依赖关系,自适应地调整特征响应值,使其适配各通道与对应空间。CBAM 结构如图 3 所示。




图 3 CBAM 结构图

Fig. 3 Diagram of CBAM structure

3 网络模型结构设计

MSCNN 模型从不同分支的原始振动信号中学习并融合更多的高维特征数据以提高模型故障识别的准确率。模型将振动数据进行分支提取数据特征,提高了模型对高维数据特征的敏感性。MSCNN 在各分支融入注意力机制模块,极大提升了对在复杂环境中运行的旋转机械故障识别准确率。

首先,将采集到的轴承振动信号进行数据分割,分割成不同大小的子振动信号,每个子信号的长度为 4 096 个振动数据,再将子信号按比例划分为 3 段振动信号作为网络模型 3 个分支的输入,送到随后的多尺度卷积中;其次,采用数个并行网络,每层网络上卷积核的大小不一,分别对输入的多分支信号进行特征提取,再将各分支信号进行特征融合;之后,将融合后的

特征输入至深度残差网络中进行卷积处理,并采用 CBAM 注意力机制进行注意力识别;最后,对高维度故

障特征数据进行全局平均池化与全连接操作,实现故障分类。模型整体结构如图4所示。




图4 多分支稀疏残差模型图

Fig. 4 Plot of the multi-branch sparse residual model

3.1 多分支结构

CNN 模型结构单一,而现场收集的振动信号包含不同维度的故障特征,使用单分支 CNN 提取特征效果不佳。为了解决这个问题,MBSRN 模型通过多分支结构提取信号不同维度的故障特征。具体而言,假设输入特征为 X_1 ($X_1 \in \mathbf{R}^{L_1 \times 1 \times C}$),则 X_1 的特征大小为 L_1 , C 表示通道数。需要将 X_1 拆分为 3 个分支子特征 X_2 , X_3 和 X_4 ,它们的大小分别为 L_2 , L_3 和 L_4 , $L_1 = L_2 + L_3 + L_4$ 。值得注意的是,不同卷积层的卷积核大小是不同的,这些卷积层需要被分配不同的特征,因此 $L_2 \neq L_3 \neq L_4$ 且 $L_2 < L_3 < L_4$ 。

在深度神经网络识别特征的过程中,特征的大小是逐层缩减的,缩减的倍数通常是 2 的指数幂。因此,为了确保特征是可分的,特征大小通常设置为 2 的指数幂。据此特点,研究人员多使用 2 的整数倍幂长度信号作为输入,这样可以提高神经网络对特征的识别性能^[19-20]。受这些文章的启发,本文设置了输入特征 $X_1 - 2^n$,即 $L_1 = L_2 + L_3 + L_4 = 2^n$ ($n \in \mathbf{N}^*$, $\mathbf{N}^*$ 表示正整数集合)。当特征大小为 2^n 时,神经网络可以更容易地识别特征,因此 L_2 , L_3 和 L_4 的值为 2 的指数幂时效果最优。按此方法设置 L_2 , L_3 , L_4 的长度,则三者之和与 2^n 构不成倍数关系 ($2^a + 2^b + 2^c \neq 2^n$, $a, b, c \in \mathbf{N}^*$ 并且 $a \neq b \neq c$)。因此,只能尝试使 L_2 , L_3 和 L_4 中的两个值满足 2 的指数幂。此外,根据指数函数的特点,不同特征之间的大小差异过大会导致一个特征过大或过小,不利于多尺度特征学习。因此, L_2 , L_3 和 L_4 之间的差异不应太大。值得注意的是, 2^n 满足式(3):

$$2^n = 2^{n-1} + 2^{n-2} + 2^{n-3} \quad (n > 3) \quad (3)$$

根据上述尺寸范围和式(3),推导出 L_2 , L_3 和 L_4 的以下两种设置方法:

$$L_2 = 2^{n-3}, L_3 = 2^{n-2}, L_4 = 2^{n-1} \quad (4)$$

$$L_2 = 2^{n-3}, L_3 = 2^{n-2}, L_4 = 2^{n-1} + 2^{n-3} \quad (5)$$

MBSRN 模型建立了特征分割的多分支模块,特征将被分成 3 个分支,并被输入到随后的多尺度卷积中。

3.2 多尺度卷积层

MBSRN 模型构建了 4 层特征提取层,在单个特征提取层中使用一维卷积核来提取振动信号的故障特征。为深度提取多尺度特征信息,在每一层上使用大小不同的一维卷积核。每个特征提取层卷积核的大小由该层输入特征的尺寸决定,卷积核的大小与特征的尺寸成正比。在图4中, $\text{Conv}(a_1)$, $\text{Conv}(a_2)$, $\text{Conv}(a_3)$ 和 $\text{Conv}(a_4)$ 的输入分别是多分支特征 X_1 , X_2 , X_3 和 X_4 ,多分支特征的大小的顺序是 $X_2 < X_3 < X_4 < X_1$,因此多尺度卷积核的大小顺序为 $a_2 < a_3 < a_4 < a_1$,最后需要融合这些输出特征。在融合过程中,首先融合 o_2 , o_3 和 o_4 ,因为它们是原始数据拆分的多分支输出要素,三者融合为特征尺度向量 o_c 。如式(6)所示:

$$o_c = o_2 \odot o_3 \odot o_4 \quad (6)$$

其中, $\odot$ 表示特征级联,将 o_2 , o_3 , o_4 展开后再进行拼接。 o_2 , o_3 和 o_4 展开后的特征尺寸分别为 L_2 , L_3 和 L_4 ,三者拼接后与原特征大小相同。最后, o_c 和 o_1 融合。由于 o_1 的特征大小为 L_1 ,因此对两者进行逐元素求和融合特征数据,如式(7)所示:

$$O = o_c \oplus o_1 \quad (7)$$

其中, $\oplus$ 表示逐元素求和, $O \in \mathbf{R}^{L_1 \times 1 \times C}$ 。

由于原始输入包含非常重要的特征信息,因此构造 $\text{Conv}(a_1)$ 以从原始输入中提取特征。与其他分支特征尺寸相比,原始输入的特征尺寸最大,因此 $\text{Conv}(a_1)$ 的卷积核也最大。

3.3 稀疏残差网络

首先设计卷积块和残差块来自动提取多分支模块提取的高级特征,然后将其与多个卷积和批量归一化

层合并,最后,通过 Softmax 实现故障的分类。残差学习可以实现跨层连接,解决深度神经网络因梯度消失导致参数无法优化的问题。融合残差结构的 CBAM 与 Conv 的连接方式如图 5 所示。




图 5 稀疏残差结构图

Fig. 5 Structure diagram of sparse residuals

4 仿真实验与工程验证

4.1 实验数据描述

使用凯斯西储大学(CWRU)数据集进行模型训练与验证。数据集分为健康数据、轻度磨损(0.177 8 mm)、中度磨损(0.355 6 mm)、重度磨损(0.533 4 mm),共 10 组数据样本。

实验采用 python 编程语言,pytorch 深度学习框架,使用 Adam 优化算法更新模型参数。按 6:2:2 的比例划分样本数据,分别用作训练集、测试集和验证集,所有类型样本的参数如表 1 所示。


表 1 试验台数据描述

Table 1 Description of test bench data


故障类型	尺寸/mm	训练数量	验证数量	测试数量	标签
正常	0	1 200	400	400	0
滚动体故障	0.177 8	1 200	400	400	1
	0.355 6	1 200	400	400	2
	0.533 4	1 200	400	400	3
内圈故障	0.177 8	1 200	400	400	4
	0.355 6	1 200	400	400	5
	0.533 4	1 200	400	400	6
外圈故障	0.177 8	1 200	400	400	7
	0.355 6	1 200	400	400	8
	0.533 4	1 200	400	400	9

4.2 结果分析


每组实验重复 10 次,实验结果取各项指标的平均值。由图 6 可知:在训练阶段,当 epoch 取值在 100 附近,训练集和测试集在无噪声情况下,损失值与识别准确率逐步收敛并稳定在 99% 附近。为了模拟现场环境中强噪声情况,通过信噪比的方式对原始信号进行处理,其中信噪轻度系数为 8,使其数据分布更加符合真实的现场数据,在强噪声情况下损失准确值在收敛前期会出现不稳定现象,但最终也达到 95% 左右并趋于稳定。这表明模型有着较强的抗噪声能力,且训练时并未出现过拟合。




(a) 无噪声训练损失值



(b) 无噪声训练准确值



(c) 强噪声损失值



(d) 强噪声准确值

图 6 不同模型诊断精度

Fig. 6 Diagnostic accuracy of different models

4.3 模型结构性能验证

模型的核心是通过分支结构、通道注意力机制和残差连接从不同角度学习和融合数据丰富的特征,以获得更好的性能。因此,需要从这 3 个不同结构来探讨不同特征信息对模型故障诊断性能的影响。分别在无噪声和强噪声的场景下进行消融实验,并记录整个过程中模型不同结构的测试精度。

为了定量评估模型 3 个结构的有效性,在实验中设置了 3 种模型结构,评估结果如表 2 所示。模型在强噪声与无噪声条件下的识别准确率均高于其他 3 种结构搭建的模型,这说明采用分支结构的策略,并在各分支上融合 CBAM 与稀疏残差可以提升模型故障的识别率。3 种结构从多个信号分量中学习更多的故障特征,与原始信号特征相互补充,提高了模型学习故障噪声特征的准度率。

表 2 不同模型结构准确率
Table 2 Accuracies of different model structures

分支 结构	CBAM 注意 力机制	稀疏残 差连接	准确率/%	
			无噪声	强噪声
—	✓	✓	66.8	65.8
✓	—	✓	89.2	78.8
✓	✓	—	97.8	82.3
✓	✓	✓	99.2	95.8

4.4 工程验证


在工程应用中,由于生产环境复杂,产生的振动数据受到多种环境噪声干扰,这要求模型有着较强的抗噪声干扰能力,同时也要有较高的故障识别准确率。为了验证模型实际工作性能,使用某水泥厂生产设备产生的振动数据进行验证。

将水泥生产设备水泥磨主排风机的故障状态作为工程验证对象,系统采样频率为 51.2 kHz。实际生产中,生产设备大多处于正常工作状态,产生的故障数据样本缺少,且很少存在一台生产设备同时发生多种故障的情况,所以本文针对水泥磨主排风机一种故障进行分类诊断。经现场人工分析水泥磨主排风机出现轴承外圈故障,收集电机自由端 1H 监控点的振动数据,测点分布如图 7 所示。

数据集共分为 2 种状态,即水泥磨主排风机的正常和故障。将采集的 1H 测点数据按 6 : 2 : 2 的比例进行划分,划分策略与 CWRU 数据相同。并采用 CNN、WDCNN 和 CNN-LSTM 模型作为对比。每次测试过程重复 10 次,对比模型与其他深度学习模型的诊断性能,不同模型在不同水泥生产设备的故障识别准确率如图 8 所示。



(a) 水泥磨主排风机实物图电机自由端 1H 测点



(b) 水泥磨主排风机三维图

图 7 某水泥厂水泥生产设备及测点位置

Fig. 7 The location of cement production equipment and measuring points of a cement plant




图 8 模型对比准确率

Fig. 8 Comparison of model accuracies

由图 8 可知:模型对水泥磨主排风机水泥生产设备的故障识别准确率为 99.9%。传统 CNN 模型的准确率仅为 70%,WDCNN 和 CNN-LSTM 的表现性能不如本文提出的算法模型。由于水泥磨主排风机的工作环境恶劣,产生大量干扰信号,严重影响对比模型的特征提取能力,而模型在数据集中都保持着较高的分类精度,说明 MSCNN 模型抗噪声能力较突出,且有着优异的特征提取能力,工程应用价值大。

5 结 论

以多分支结构结合通道注意力机制与残差连接的方案改进传统 CNN,形成一种可以有效识别关键故障特征,具备较强抗噪能力的模型。主要结论如下:

(1) 该模型将输入分为不同的分支,通过多分支学习提取轴承的关键故障特征,并采用通道注意力机

制进行特征融合,提高故障诊断效率和准确性,并采用残差连接解决梯度消失与梯度爆炸。

(2) 该模型采用不同分支策略,在不同尺度上利用 CBAM 抑制振动信号中噪声的干扰,提升了故障特征的识别率。经多次实验发现:在强噪声信号条件下,模型通过引入不通网络结构和并行化网络结构设计,使模型识别准确率得到了较高提升。

(3) 经过对比实验可知:模型对故障识别的准确率不低于 97%;在水泥生产工艺环境下,故障识别准确率均稳定在 95% 以上,具备较强的特征提取能力、优秀的抗噪能力和噪声鲁棒性。

参考文献(References):

- [1] 于军, 丁博, 何勇军. 基于平均多粒度决策粗糙集和 NNBC 的滚动轴承故障诊断[J]. 振动与冲击, 2019, 38(15): 209-215.
YU Jun, DING Bo, HE Yong-jun. Rolling bearing fault diagnosis based on mean multi-granularity decision rough set and NNBC[J]. Journal of Vibration and Shock, 2019, 38(15): 209-215.
- [2] CHEN Z, GRYLLIAS K, LI W. Mechanical fault diagnosis using convolutional neural networks and extreme learning machine[J]. Mechanical Systems and Signal Processing, 2019, 133: 106272.
- [3] SHAO H, JIANG H, ZHANG H, et al. Electric locomotive bearing fault diagnosis using a novel convolutional deep belief network[J]. IEEE Transactions on Industrial Electronics, 2018, 65(3): 2727-2736.
- [4] WEN L, GAO L, LI X. A new deep transfer learning based on sparse auto-encoder for fault diagnosis[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019, 49(1): 136-144.
- [5] 卞景艺, 刘秀丽, 徐小力, 等. 基于多尺度深度卷积神经网络的故障诊断方法[J]. 振动与冲击, 2021, 40(18): 204-211.
BIAN Jing-yi, LIU Xiu-li, XU Xiao-li, et al. Fault diagnosis method based on a multi-scale deep convolutional neural network[J]. Journal of Vibration and Shock, 2021, 40(18): 204-211.
- [6] LI T, ZHAO Z, SUN C, et al. Adaptive channel weighted CNN with multisensor fusion for condition monitoring of helicopter transmission system[J]. IEEE Sensors Journal, 2020, 20(15): 8364-8373.
- [7] ZHANG W, LI C, PENG G, 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.
- [8] NIU G, LIU E, WANG X, et al. Enhanced discriminate feature learning deep residual CNN for multitask bearing fault diagnosis with information fusion[J]. IEEE Transactions on Industrial Informatics, 2023, 19(1): 762-770.
- [9] HUANG W, GAO G, LI N, et al. Time-frequency squeezing and generalized demodulation combined for variable speed bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68(8): 2819-2829.
- [10] ZHANG L, XIONG G, LIU H, et al. Bearing fault diagnosis using multi-scale entropy and adaptive neuro-fuzzy inference[J]. Expert Systems with Applications, 2010, 37(8): 6077-6085.
- [11] JIANG G, HE H, YAN J, et al. Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox[J]. IEEE Transactions on Industrial Electronics, 2019, 66(4): 3196-3207.
- [12] HUANG W, CHENG J, YANG Y, et al. An improved deep convolutional neural network with multi-scale information for bearing fault diagnosis[J]. Neurocomputing, 2019, 359: 77-92.
- [13] 赵小强, 梁浩鹏. 使用改进残差神经网络的滚动轴承变工况故障诊断方法[J]. 西安交通大学学报, 2020, 54(9): 23-31.
ZHAO Xiao-qiang, LIANG Hao-peng. Fault diagnosis method for rolling bearing under variable working conditions using improved residual neural network[J]. Journal of Xi'an Jiaotong University, 2020, 54(9): 23-31.
- [14] WEN L, LI X, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50[J]. Neural Computing and Applications, 2020, 32(10): 6111-6124.
- [15] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2022.
QIU Xi-peng. Neural networks and deep learning[M]. Beijing: Machinery Industry Press, 2022.
- [16] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [17] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning[C]//Proceedings of the 31st AAAI Conference on Artificial Intelligence. New York: ACM, 2017: 4278-4284.
- [18] FU Q, LI S, WANG X. MSCNN-AM: A multi-scale convolutional neural network with attention mechanisms for retinal vessel segmentation[J]. IEEE Access, 2020, 8(6): 163926-163936.
- [19] HU Z X, WANG Y, GE M F, et al. Data-driven fault diagnosis method based on compressed sensing and improved multiscale network[J]. IEEE Transactions on Industrial Electronics, 2020, 67(4): 3216-3225.
- [20] ZHAO B, ZHANG X M, ZHAN ZH, et al. Deep multi-scale separable convolutional network with triple attention mechanism: A novel multi-task domain adaptation method for intelligent fault diagnosis[J]. Expert Systems with Applications, 2021, 182: 1150.

责任编辑:李翠薇