

一种具有强抗噪性的深度学习故障诊断模型

吴春志, 吴守军, 冯辅周, 朱俊臻

(陆军装甲兵学院车辆工程系, 100072, 北京)

摘要: 针对旋转机械运行环境噪声大, 现有的基于深度学习的故障诊断模型抵抗强噪声干扰能力不足的问题, 提出了一种具有强抗噪性的深度学习故障诊断模型(HAT-MSCNN)。首先将齿轮箱训练集正常状态下样本的频谱信号由大到小排列, 取排序的第 k 个的幅值 α 为基准值, 将训练集中所有样本的频谱信号低于 α 的值置0, 降低了易与噪声耦合的低幅值频率成分对诊断模型的干扰, 突出了高幅值频率成分对故障诊断模型的贡献, 同时保留零值所在的位置信息。然后将经过此处理的训练集输入到由多种移动步长卷积核组合的多尺度卷积神经网络中进行训练, 最终得到强抗噪性的故障诊断模型。以精确率和召回率的调和平均值 F 作为模型的评价指标, 并使用加权梯度类激活映射方法可视化模型的分类权重, 在具有丰富故障模式的PHM2009齿轮箱数据集上验证模型。将所提模型与以原始振动信号作为输入的Raw-MSCNN模型、以频谱信号作为输入的Frequency-MSCNN模型、以集合经验模态分解(EEMD)降噪后的信号作为输入的EEMD-MSCNN模型和以所提训练集样本构造方法处理后的信号作为输入的HAT-CNN模型进行对比, 结果表明, 所提模型在测试集信噪比为-4 dB时, 诊断的 F 值为98.6%, 比第二名的Frequency-MSCNN高了6.4%, 在更强噪声干扰的测试集信噪比为-6 dB时, F 值为89.1%, 比Frequency-MSCNN高了10.9%, 证明了所提的HAT-MSCNN模型具有在强噪声干扰下的抗噪能力。

关键词: 故障诊断; 卷积神经网络; 降噪; 齿轮箱

中图分类号: TP206 **文献标志码:** A

DOI: 10.7652/xjtuxb202104007 **文章编号:** 0253-987X(2021)04-0061-08



OSID 码

A Deep Learning Fault Diagnosis Model with Strong Anti-Noise Ability

WU Chunzhi, WU Shoujun, FENG Fuzhou, ZHU Junzhen

(Department of Vehicle Engineering, Academy of Army Armored Forces, Beijing 100072, China)

Abstract: A deep learning fault diagnosis model with strong anti-noise ability (HAT-MSCNN) is proposed to solve the problem that the existing fault diagnosis model based on deep learning has insufficient resistance to strong noise interference due to the high noise in the operating environment of rotating machinery. Firstly, the frequency spectrum signals of the samples under normal state of the gearbox training set are arranged from large to small, and the k th amplitude value α of the sort is taken as the reference value. The frequency spectrum signals of all samples in the training set with values being lower than the value of α are set to zero, which reduces the interference of low-amplitude frequency components that are easy to be coupled with noise on the diagnosis model, and highlights the contribution of high-amplitude frequency components to the fault diagnosis model and retains the position information where the zero value is located. Then

收稿日期: 2020-07-23。 作者简介: 吴春志(1991—),男,博士生;冯辅周(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(51875576)。

网络出版时间: 2020-11-30

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20201130.1054.004.html>

the processed training set is inputted into a multi-scale convolutional neural network composed of multiple moving step size convolution kernels for training, and finally a fault diagnosis model with strong noise immunity is obtained. The harmonic average value F of precisions and recalls is used as an evaluation index of the model, the weighted gradient activation mapping method is used to visualize the classification weights of the model, and the model is verified on the PHM2009 gearbox data set with rich failure modes. The proposed method is compared with the Raw-MSCNN, Frequency-MSCNN, and EEMD-MSCNN models that use vibration signals, frequency signals, and EEMD denoised signals as input respectively, and the HAT-CNN model that uses the signal processed by the proposed training set sample construction method as input. The results show that when the SNR of the test set is -4 dB, the F value of the proposed HAT-MSCNN is 98.6%, which is 6.4% higher than that of the second-place Frequency-MSCNN. When the SNR of the test set with stronger noise interference is -6 dB, the F value of the proposed HAT-MSCNN is 89.1%, which is 10.9% higher than that of Frequency-MSCNN. It proves that the proposed model has the anti-noise capability under strong noise interference.

Keywords: fault diagnosis; convolutional neural network; noise reduction; gearbox

旋转机械是指主要依靠旋转动作完成特定功能的机械,典型的旋转机械有齿轮箱、减速机、汽轮机、燃气轮机、风机、发电机、发动机等。以齿轮箱为例,作为传动系统的关键部件,其广泛应用于风力发电机组、煤矿开采设备、车辆传动机构等很多重要的机械设备。齿轮箱故障可能会造成生产停滞,甚至导致人员伤亡^[1]。齿轮箱的主要故障有不平衡、轴承不对中、松动及齿轮部件的断裂磨损等^[2-3]。因此,对旋转机械进行在线监测与故障诊断成为系统设计和维护中非常关键的环节^[4-5]。

在齿轮箱的实际工作中,运行工况多变,在实际工作中采集齿轮箱的振动信号,远比台架试验中得到的信号受噪声干扰严重^[6]。但是,由于条件有限,在实际应用环境中得到特定故障信号有一定的难度,因此由人为在台架试验中注入故障是进行不同故障模式信号收集、建立故障诊断模型最直接有效的手段^[7]。如何平衡台架试验与实际环境应用间的矛盾,是摆在故障诊断模型进一步应用的难题。

深度学习是近年来人工智能领域研究的热点,作为代表的卷积神经网络以其特有的网络结构和训练方式,直接以原始信号作为输入,模拟输入和输出之间的复杂关系,减少了对专家经验的依赖,也无需人工提取特征,在旋转机械故障诊断中应用也越来越广泛^[8-11]。但是,传统的深度学习模型鲁棒性差,诊断准确率易受噪声影响,为此,一些学者从数据和算法两个方面,提出了对噪声有一定抵抗能力的深度学习故障诊断模型。文献[12]使用自编码器先对信号降噪再输入到一维卷积神经网络(1-DCNN)模

型中实现降噪,但需要训练两个模型,而且测试信号的信噪比仅为 1 dB。文献[13-16]提出了具有一定抗噪性的深度学习模型,可以不对数据进行处理,但是,测试信号的信噪比最低仅为 0 dB,对低于 0 dB 的强噪声干扰没有研究或者诊断效果较差。

本文在文献[17]改进的 1-DCNN 模型基础上引入多尺度的概念,提出多尺度卷积神经网络(MSCNN)模型。该模型可以降低训练集信号间隔的敏感度,提高诊断的准确率^[18]。同时提出一种高幅值截断(HAT)的频谱信号处理方法,处理后的频谱信号作为训练集训练 MSCNN 模型,然后在不同的信噪比测试集中进行测试。将本文模型与集合经验模态分解(EEMD)降噪方法、直接以振动信号和频谱信号作为输入的 MSCNN 模型以及使用 1-DCNN 模型的方法进行对比,以不同信噪比测试集中的精确率和召回率的调和平均值为评价指标,采用具有丰富故障模式的 PHM2009 齿轮箱故障数据集在强噪声干扰下进行测试,验证本文模型的抗噪能力,同时使用加权梯度类激活映射(Grad-CAM)方法可视化显示模型的分类权重。

1 MSCNN 模型

将传统用于二维图像识别的卷积神经网络模型改造成用于一维信号的 1-DCNN,如图 1 所示。一个完整的 CNN 模型包括了输入层、CNN 层组(由卷积层和池化层组成)、全连接层、输出层等几个部分。

为了提高特征提取的维度,将多尺度的概念引入 1-DCNN 中,即增加多种步长移动方式,以提取




图 1 1-DCNN 网络结构图

Fig. 1 Structure of 1-DCNN network

信号不同尺度的特征,扩充特征维度,得到 MSCNN 模型,如图 2 所示。其中,convd₁、convd₂、convd₃ 分别代表移动步长为 1、2、3 的卷积核。不同的 CNN 层组搭配不同移动步长的卷积核,可以使卷积后得到不同尺度的特征量。不同尺度的特征之间差异性相对较大,这增加了特征提取的丰富程度。




图 2 多尺度卷积神经网络模型

Fig. 2 Structure of multi-scale convolutional neural network

2 Grad-CAM 方法

在网络进行全连接之前,卷积层保留了丢失的空间信息,Grad-CAM 方法^[19]可利用最后一层卷积层的梯度信息,然后将信息反向传播到其他卷积层,以此来了解该卷积中每个特征图对特定分类做出决策的重要性,即权重。将卷积层的特征图与其对应的重要性权重相乘后,就得到了所分类的特征定位图。与 CAM 方法不同,Grad-CAM 方法不需要将网络修改为平均池化重新训练,对于含有全连接层的一般网络可直接使用,具体可分为以下 6 个步骤。

- (1)假设 $L_{c, \text{Grad-CAM}} \in c^{u \times v}$ 是类别 c 的定位图,其中 u 和 v 是其宽度和高度。
- (2)在输出层之前计算类别 c 的梯度 y_c 。
- (3)提取所测卷积层参数,若卷积核个数为 Q ,将 y_c 分别对 Q 个特征图求偏导,其中第 q 个特征图为 A_q ,求偏导为 $\frac{\partial y_c}{\partial A_q}$ 。
- (4)分别对 Q 个特征图的梯度求像素平均,获得该特征图的重要性权重,计算公式如下

$$\alpha_{c,q} = \frac{1}{Z} \sum_i \sum_j \frac{\partial y_c}{\partial A_q} \quad (1)$$

式中: $\alpha_{c,q}$ 为第 q 个特征图对类别 c 决策的重要性; Z 为 A_q 的像素数; $A_{q(i,j)}$ 为 A_q 中 (i,j) 处的像素值。

- (5)将 Q 个特征图与其对应的权重 $\alpha_{c,q}$ 相乘再求和就得到了 $L_{c, \text{Grad-CAM}}$ 。对类别 c 有正向贡献的特征值应该被关注,而负向贡献的应该舍弃,因此增加一个修正线性单元(ReLU)作为激活函数,将小于 0 的特征值置 0,由此可得

$$L_{c, \text{Grad-CAM}} = \text{ReLU} \left(\sum_q \alpha_{c,q} A_q \right) \quad (2)$$

- (6)将得到的 $L_{c, \text{Grad-CAM}}$ 重采样,匹配输入的样本大小,即可得到网络对样本的分类权重定位图。

3 测试集构建

本文以 PHM2009 Challenge Data 数据库的斜齿轮故障为例进行分析。该数据集是 PHM 协会在 2009 年国际竞赛的全套齿轮箱数据。斜齿轮箱结构如图 3 所示。斜齿轮啮合模式下共有 8 种包含齿轮裂纹、断齿,轴承滚动体、内圈、外圈以及轴的不平衡、键槽磨损等单一及复合故障模式(Spur1~Spur8)^[20]。采样频率为 66.67 kHz,采样时间为 4 s,采样点数为 266 656。为了优化模型的运算速度,在有限数据样本内包含更多周期的信号,对原信号进行降采样 1/3 处理。取样本数据段长度为 1 600




图 3 PHM 2009 Challenge Data 斜齿轮箱结构

Fig. 3 Structure of the gearbox of PHM 2009 Challenge Data

点,可以包含 2~3 个周期的振动数据。

齿轮箱在试验中测得的振动信号本身就包含一定的噪声,并不是纯净的故障模式振动信号,但是相对于实际应用情况,试验台得到的信号信噪比相对较高,因此为了模拟实际工作中可能遇到的噪声情况,在信号中添加不同信噪比的高斯白噪声。

信噪比 R_{SN} 的定义如下

$$R_{SN} = 10\lg\left(\frac{P_{\text{signal}}}{P_{\text{noise}}}\right) = 20\lg\left(\frac{A_{\text{signal}}}{A_{\text{noise}}}\right) \quad (3)$$

式中: P_{signal} 和 P_{noise} 分别代表信号和噪声的有效功率; A_{signal} 为信号的平均幅值; A_{noise} 为噪声平均幅值。信噪比的单位为 dB。为了更好地显示噪声对信号的影响,列出信号幅值与噪声幅值的比值 $A_{\text{signal}}/A_{\text{noise}}$,该比值与信噪比的关系如表 1 所示。

为了更直观的展示不同信噪比的含噪信号,以 Spur2 信号为例,图 4 显示出不同信号比下含噪信号、噪声信号以及含噪信号的频谱。结合表 1 和图 4 可知,当信噪比为 0 dB 时,噪声信号和原信号的

幅值比为 1:1,此时频谱图还能基本保未加噪声时的形状(如图 4c 所示),但当信噪比继续减小,尤其是减小到-10 dB 时,噪声幅值已经是原信号的 3 倍(如图 4h 所示),频谱图中已经看不到原信号大概形状,低幅值的频率都湮没在噪声中。因此,若使提出的抗噪模型有效果,则至少应满足在 0 dB 时保持较高的诊断精确率。

在时域中进行降噪处理很难完全将加入的噪声分量剔除出去,由图 4 可知,在信噪比取一定范围内,含噪信号的频谱图整体趋势是不变的。如果将幅值小于某一定值的频率直接置 0,只考虑幅值较大的几个频率值,将调整后的频谱信号作为输入,将在一定程度上减弱噪声的影响。以 PHM2009 齿轮箱的正常信号 Spur1(35 Hz 转速下低负载)为例进行分析。

图 5 是进行 HAT 处理的流程,在求取频谱后,按照幅值从大到小的顺序排列,然后取前 k 个为有效值,第 k 个值为 α ,然后将小于 α 的值置 0,得到最

表 1 信号噪声幅值比与信噪比关系

Table 1 Relationship between signal-to-noise amplitude ratio and SNR

R_{SN}/dB	-10	-8	-6	-4	-2	0	2	4	6	8	10
$A_{\text{signal}} \cdot A_{\text{noise}}^{-1}$	0.32	0.4	0.5	0.63	0.79	1.0	1.26	1.58	2.0	2.51	3.16




图 4 不同信噪比下含噪信号、噪声信号时域图与含噪信号频谱图

Fig. 4 Time domain diagrams of signal with noise and noise signal, and spectrums of signal with noise under different SNR

终的 HAT 频谱向量(该频谱向量的长度为原样本经过求取频谱后再经 HAT 处理后的数据点数,用符号 N 表示)。通过实验发现, k 值过大起不到降噪效果,过小会影响样本的有效数据量。在本次研究中 k 值统一取 30,整个数据集 α 的确定以正常信号下第 30 个频率值的平均幅值为准,本数据集中 α 为 0.029。采用 HAT 处理数据集后,减弱了频谱中幅值低的频率成分对分类的权重贡献,减少低幅值噪声信号对信号的干扰,但是依然保留了 0 值所在的位置信息。降低了加噪信号和原信号之间的差异,突出高幅值频率成分的权重贡献。




图5 HAT处理频谱信号流程

Fig. 5 Flow chart of HAT processing frequency signals

Spur1 在加入不同信噪比噪声数据后进行 HAT 转换可得到图 6,可以看出在信噪比为 0 dB 时,数据结构变化不大,但是当信噪比继续增大到 -5 dB 甚至 -10 dB 时,HAT 后的数据也几乎湮没在噪声信号里。HAT 转换后的频谱不止是特征数值上的信息,还包括了特征的位置信息。





图6 Spur1 在不同信噪比下 HAT 处理后的信号

Fig. 6 Spur1 signal after HAT processing under different SNR

4 算例分析

本节中采用未作处理的直接以振动信号进行输入的 Raw-MSCNN 模型、经过 EEMD 降噪的振动信号作为输入的 EEMD-MSCNN 模型、以原始频谱信号作为输入的 Frequency-MSCNN 模型和本文提出的 HAT-MSCNN 模型以及作为对比的 HAT-CNN 模型(在后续图表中省略 MSCNN 和 NN),在试验台取得的振动信号组成的训练集中进行训练,在添加不同信噪比高斯白噪声的测试集中进行测试,对 PHM2009 齿轮箱故障数据做故障诊断研究,具体流程如图 7 所示。




图7 5种模型训练和测试的流程

Fig. 7 Flow chart of training and testing of five models

在 Raw-MSCNN 和 EEMD-MSCNN 模型中,输入数据都是基于时域信号,样本长度为 1 600 点,为了保证模型的一致性,在应用 Frequency-MSCNN、HAT-MSCNN 和 HAT-CNN 时取样本长度为 3 200 点,然后求得频谱信号长度为 1 600 点,测试集信噪比与表 1 设置一致。两种深度学习网络卷积核大小都设置为 21 和 11,学习率为 5×10^{-4} 。1-DCNN 两个层组的卷积核数量为 8 和 15, MSCNN 为 6 和 10,这样在全连接层的神经元数量都为 6 000,保证了特征提取数量的一致。

抗噪模型至少应在信噪比为 0 dB 时保持较高的诊断精确率。因此本文采用 t 分布领域嵌入算法 (t-SNE) 分析在 $R_{SN}=0$ dB 时, 测试集样本在不同模型下全连接层的聚类效果, 得到图 8。其中 t-SNE 的参数设置为 PCA 模式, 最大迭代次数 10 000, 学习率为 500。

t-SNE 关心的是学习维持数据的局部结构, 降到 2 维空间时会保留数据的流形结构, 类间的距离远近不代表真实数据的分类距离, 是一个聚类示意图。由图 8 可知, HAT-MSCNN 和 Frequency-MSCNN 在信噪比为 0 dB 时分类效果最好, 其他模型在聚类过程中都有重叠, 分类效果较差。

由于在增加了高斯白噪声后, 模型的诊断的精确率和召回率偏差较大, 因此本节采用二者的调和平均值 F 作为评价指标, 其计算方法如下

$$F = \frac{(1 + \beta^2) P_{\text{recall}} P_{\text{precision}}}{\beta^2 P_{\text{recall}} + P_{\text{precision}}} \tag{4}$$

式中: 参数 β 一般取 1; P_{recall} 是召回率; $P_{\text{precision}}$ 是精确率。

表 2 比较了几种模型在不同信噪比噪声信号中的 F 值, 由表 2 可知, HAT-MSCNN 和 Frequency-MSCNN 相较于其他几种模型, 在较强噪声干扰 ($R_{SN}=-4$ dB) 时仍能保持较高的诊断性能。当信噪比较低时, 尤其是 HAT-MSCNN, 在 $R_{SN}=-6$ dB 时, F 值达到了 89.1%, 在 $R_{SN} \geq -4$ dB 时, F 值超过了 98%。HAT-CNN 模型在 $R_{SN} \leq -4$ dB 时无法分类故障, 说明 1-DCNN 对数据加噪敏感。因此, 在强噪声环境下, HAT-MSCNN 具有更高的抗噪性和故障特征学习能力。

使用 Grad-CAM 方法得到的本文模型对不同故




图 8 $R_{SN}=0$ dB 时不同模型对 8 种故障模式信号的 t-SNE 可视化聚类结果

Fig. 8 t-SNE visualization results of 8 fault modes in test sample set by different models when $R_{SN}=0$ dB

表 2 几种模型在不同信噪比噪声信号中的 F 值比较

Table 2 F values of several models in different-SNR signals

模型	F / %							
	$R_{SN}=-10$ dB	$R_{SN}=-6$ dB	$R_{SN}=-4$ dB	$R_{SN}=-2$ dB	$R_{SN}=0$ dB	$R_{SN}=2$ dB	$R_{SN}=4$ dB	$R_{SN}=6$ dB
RAW	42.3	50.4	71.5	78.9	86.8	91.1	95.5	97.5
EEMD	21.2	44.2	57.5	51.2	63.1	86.4	90.3	95.6
Frequency	53.5	78.2	92.2	95.5	98.7	100.0	100.0	100.0
HAT-CNN	17.2	18.4	18.6	80.5	98.3	100.0	100.0	100.0
HAT	57.2	89.1	98.6	99.5	100.0	100.0	100.0	100.0

障类型分类权重的可视化结果如图 9 所示。图 9 表明,本文模型对不同故障类型关注的侧重点不同,幅值较高的特征部分更加突出,减少了可能会被噪声影响的幅值较低的频率成分对分类的干扰。




图 9 本文模型对不同故障类型的分类权重可视化结果
Fig. 9 Visualization results of classification weights of different fault types by the proposed model

图 10 是本文模型对 Spur5 不同信噪比的测试信号的分类权重,结合图 9e 可知,本文模型对于分类成 Spur5 的故障模式,更加关注其 250 点和 800 点左右的成分,这两个点附近对应的频率在频谱中





图 10 本文模型对 Spur5 不同信噪比的测试信号的分类权重可视化结果
Fig. 10 Visualization results of the proposed model's classification weights of Spur5 test signals with different SNR

幅值占比较高。在不同信噪比的噪声信号中,本文模型准确地找到了这两个频率段的特征。

5 结 论

本文提出一种强抗噪性的故障诊断模型 HAT-MSCNN,实现了在强噪声干扰下齿轮箱多种复合故障的诊断识别。首先使用高幅值截断的策略构建训练集,然后输入到多尺度卷积神经网络模型进行故障诊断,同时使用 Grad-CAM 方法可视化显示分类权重。经 HAT 处理后的信号突出了幅值较高的频率成分,降低了低幅值频率成分被噪声耦合后对模型诊断的影响。实验结果表明,直接以频谱信号作为输入的诊断模型虽对噪声有一定的抵抗能力,但 HAT-MSCNN 模型在信噪比为 -4 dB 时,诊断准确率为 98.6% ,而在信噪比为 -6 dB 时,诊断准确率依然能保持在 90% 左右,远高于其他模型。因此,HAT-MSCNN 模型可以有效减少噪声对诊断模型的影响。

参考文献:

[1] LI Chuan, SANCHEZ R V, ZURITA G, et al. Gear-box fault diagnosis based on deep random forest fusion of acoustic and vibratory signals [J]. Mechanical Systems and Signal Processing, 2016, 76/77(8): 283-293.

[2] 汤宝平,熊学嫣,赵明航,等. 多共振分量融合 CNN 的行星齿轮箱故障诊断 [J]. 振动、测试与诊断, 2020, 40(3): 507-512.

TANG Baoping, XIONG Xueyan, ZHAO Minghang, et al. A multi-resonance component fusion based convolutional neural network for diagnosis of planetary gearboxes [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3): 507-512.

[3] 周兴康,余建波. 基于深度一维残差卷积自编码网络

- 的齿轮箱故障诊断[J]. 机械工程学报, 2020, 56(7): 96-108.
- ZHOU Xingkang, YU Jianbo. Gearbox fault diagnosis based on one-dimension residual convolutional auto-encoder [J]. Journal of Mechanical Engineering, 2020, 56(7): 96-108.
- [4] 魏巍宏. 基于振动监测和油液分析的齿轮箱多参数故障诊断方法优化研究[D]. 江苏徐州: 中国矿业大学, 2019: 7-8.
- [5] 张弘斌, 袁奇, 赵柄锡, 等. 采用多通道样本和深度卷积神经网络的轴承故障诊断方法[J]. 西安交通大学学报, 2020, 54(8): 58-66.
- ZHANG Hongbin, YUAN Qi, ZHAO Bingxi, et al. A bearing fault diagnosis with multi-channel sample and deep convolutional neural network [J]. Journal of Xi'an Jiaotong University, 2020, 54(8): 58-66.
- [6] 卢昱奇. 基于卷积神经网络的行星齿轮箱复合故障诊断方法研究[D]. 成都: 电子科技大学, 2020: 2-4.
- [7] 丁闯, 冯辅周, 张兵志, 等. 行星变速箱振动信号的线性量子信息熵特征[J]. 兵工学报, 2018, 39(12): 2306-2312.
- DING Chuang, FENG Fuzhou, ZHANG Bingzhi, et al. Feature of linear quantum information entropy for vibration signals of planetary transmission gearbox [J]. Acta Armamentarii, 2018, 39(12): 2306-2312.
- [8] JANSSENS O, SLAVKOVIKJ V, VERVISCH B, et al. Convolutional neural network based fault detection for rotating machinery [J]. Journal of Sound & Vibration, 2016, 377: 331-345.
- [9] DING Xiaoxi, HE Qingbo. Energy-fluctuated multi-scale feature learning with deep ConvNet for intelligent spindle bearing fault diagnosis [J]. IEEE Transactions on Instrumentation & Measurement, 2017, 66(8): 1926-1935.
- [10] 万齐杨, 熊邦书, 李新民, 等. 基于DCAE-CNN的自动倾斜器滚动轴承故障诊断[J]. 振动与冲击, 2020, 39(11): 273-279.
- WAN Qiyang, XIONG Bangshu, LI Xinmin, et al. Fault diagnosis for rolling bearing of swashplate based on DCAE-CNN [J]. Journal of Vibration and Shock, 2020, 39(11): 273-279.
- [11] JING Luyang, ZHAO Ming, LI Pin, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox [J]. Measurement, 2017, 111: 1-10.
- [12] 李涛, 段礼祥, 张东宁, 等. 自适应卷积神经网络在旋转机械故障诊断中的应用[J]. 振动与冲击, 2020, 39(16): 275-282, 288.
- LI Tao, DUAN Lixiang, ZHANG Dongning, et al. Application of adaptive convolutional neural network in rotating machinery fault diagnosis [J]. Journal of Vibration and Shock, 2020, 39(16): 275-282, 288.
- [13] 刘冲. 基于联合抗噪算法的滚动轴承故障诊断研究[J]. 华东交通大学学报, 2020, 37(4): 82-87.
- LIU Chong. Research on joint anti-noise algorithm and its application in rolling bearing fault diagnosis [J]. Journal of East China Jiaotong University, 2020, 37(4): 82-87.
- [14] 吴静然, 丁恩杰, 崔冉, 等. 采用多尺度注意力机制的旋转机械故障诊断方法[J]. 西安交通大学学报, 2020, 54(2): 51-58.
- WU Jingran, DING Enjie, CUI Ran, et al. A diagnostic approach for rotating machinery using multi-scale feature attention mechanism [J]. Journal of Xi'an Jiaotong University, 2020, 54(2): 51-58.
- [15] 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 Xiaoqiang, LIANG Haopeng. Fault diagnosis method for rolling bearing under variable working conditions using improved residual [J]. Journal of Xi'an Jiaotong University, 2020, 54(9): 23-31.
- [16] 彭鹏, 柯梁亮, 汪久根. 噪声干扰下的RV减速器故障诊断[J]. 机械工程学报, 2020, 56(1): 30-36.
- PENG Peng, KE Liangliang, WANG Jiugen. Fault diagnosis of RV reducer with noise interference [J]. Journal of Mechanical Engineering, 2020, 56(1): 30-36.
- [17] WU Chunzhi, JIANG Pengcheng, DING Chuang, et al. Intelligent fault diagnosis of rotating machinery based on one-dimensional convolutional neural network [J]. Computers in Industry, 2019, 108: 53-61.
- [18] WU Chunzhi, FENG Fuzhou, WU Shoujun, et al. Research on multi-scale batch normalized convolutional neural networks for gearbox fault diagnosis [C]//10th Prognostics and System Health Management Conference. Piscataway, NJ, USA: IEEE, 2019: 8942850.
- [19] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2019, 128(8): 618-626.
- [20] PHM Society. PHM09_competition_1 [DB/OL]. [2017-12-01]. <https://c3.nasa.gov/dashlink/resources/997>.

(编辑 刘杨)