DOI：10.13890/j.issn.1000-128X.2023.02.012　　文章编号：1000-128X(2023)02-0103-10

基于特征融合的牵引电机轴承声学故障诊断

杨　岗[1]，卫昱乾[2]，李　芾[1]
（1.西南交通大学 机械工程学院，四川 成都　610031；
2.西南交通大学 唐山研究院，河北 唐山　063000）

摘　要：滚动轴承作为高速列车牵引电机的重要部件，其故障情况严重影响列车运行安全。声学轴承故障诊断方式具有无安装侵入性、运维成本低的优点，但也具有信噪比低、故障特征难以提取的缺点，机器学习则具有克服噪声影响的鲁棒性。针对应用机器学习进行声学故障诊断时，少量特征无法全面表征轴承故障的难题，文章提出将格拉姆角场（GAF）与小波时频图进行叠加融合，构成6通道融合特征图用以有效表征轴承的故障。首先，建立牵引电机轴承声学故障试验台获取故障声学信号；其次，建立基于GAF的声学信号融合特征图，然后使用残差网络（ResNET）模型针对融合特征图特征训练并验证故障分类模型，并与以单种特征图作为特征的故障分类方法进行准确率对比。结果表明，基于GAF的融合特征图的声学故障分类模型具有99.89%的准确率，融合特征图能更有效地映射轴承故障。

关键词：牵引电机轴承；声学故障诊断；卷积神经网络；融合特征图；格拉姆角场；高速列车
中图分类号：U292.91⁺4；U260.331⁺.2　　**文献标识码：**A

Acoustic fault diagnosis of traction motor bearing based on fusion feature

YANG Gang[1], WEI Yuqian[2], LI Fu[1]

(1. School of Mechanical Engineering, Southwest Jiaotong University, Chengdu, Sichuan 610031, China;
2. Tangshan Institute, Southwest Jiaotong University, Tangshan, Hebei 063000, China)

Abstract: The rolling bearing is an important part of the traction motor of high-speed train, and its failure seriously affects the safety of train operation. The acoustic diagnosis method for bearing fault has the advantages of non-invasive installation and low operation and maintenance cost, but it also has the disadvantages of low signal-to-noise ratio and difficult to extract fault features. Machine learning has the robustness to avoid the influence of noise. Aiming at the problem that a small number of features cannot fully characterize the bearing fault when applying machine learning to acoustic fault diagnosis, this paper proposes to superimpose and fuse the Gramian angular field (GAF) and wavelet time-frequency figure to form a six channel fusion feature map to effectively characterize the bearing fault. Firstly, the traction motor bearing acoustic fault test-bed was established to obtain the fault acoustic signal. Secondly, the acoustic signal fusion feature map based on GAF was established. Then, the residual networks (ResNETs) model was used to train and verify the fault classification model for the features of the fusion feature map, and the accuracy was compared with the fault classification method with a single feature map as the feature. The results show that the acoustic fault classification model based on GAF fusion feature map has an accuracy of 99.89%, so the fusion feature map can more effectively reflect the bearing fault.

Keywords: traction motor bearing; acoustic fault diagnosis; convolutional neural network; fusion feature map; Gramian angular field; high-speed train

---

基金项目：国家重点研发计划项目（2020YFB1200300ZL）；四川省科技计划项目（2022YFG0088）
通信作者：杨　岗（1973—），男，博士，讲师，硕士生导师，主要研究方向为交通设备故障诊断与控制工程、人工智能与大数据分析、弓网动力学与主动控制；E-mail: yanggang@swjtu.cn
引用格式：杨岗, 卫昱乾, 李芾. 基于特征融合的牵引电机轴承声学故障诊断[J]. 机车电传动, 2023(2): 103-112.
Citation: YANG Gang, WEI Yuqian, LI Fu. Acoustic fault diagnosis of traction motor bearing based on fusion feature[J]. Electric Drive for Locomotives,2023(2): 103-112.

0 引言

牵引电机作为列车的关键部件之一，其正常运行对列车安全至关重要[1]。轴承是电机传动轴的支撑构件。由于负载循环冲击、转速时变、流过漏电流等因素，轴承的内圈、外圈、保持架和滚子容易产生裂纹或点蚀等故障，对列车的运行安全造成了一定的隐患[2]。因此，对牵引电机轴承进行实时故障诊断至关重要。振动信号诊断是轴承故障诊断中最成熟的诊断方法，而且应用效果显著[3]。但是由于采集振动信号所需的加速度传感器的接触式安装方式比较复杂，振动信号诊断法在实际应用中有如下风险：安装前需对轴承座开孔，降低了轴承座强度；列车运行时的不规则振动有可能造成传感器的掉落；车载诊断系统复杂难以维护。声学信号诊断法是另一种有效的轴承故障诊断方法，其优点是可安装于轨旁，能有效克服振动诊断法的缺点，降低应用难度和运维成本[4]。但是声学信号的信噪比较低，故障特征容易被淹没，限制了声学故障诊断的应用。

在传统声学故障诊断领域，已有学者对声学信号诊断法进行了相关研究，文献[5]基于核特征矩阵联合近似对角化（Kernel Joint Approximate Diagonalization of Eigen-matrices, KJADE）对畸变的轨旁信号进行校正，提出了一种轨旁轴承声学故障诊断方法。文献[6]提出了一种动态重采样的方法，以减少轨旁信号的畸变带来的影响，使用自适应随机共振的方法，并借助辅助噪声来增强故障特征频率。文献[7]结合奇异值分解方法与共振信号稀疏分解方法，采用平滑滤波器对奇异值向量进行滤波，将轨旁声学信号分解为高共振分量与低共振分量，从低共振分量中提取到了轴承故障特征信息。文献[8]通过采用时域盲解卷积算法提取声学信号的冲击成分，并运用频域压缩感知重构信号，有效地分离出声学故障特征。文献[9]采用共振稀疏分解算法与小波降噪对声学信号进行降噪，并重构特征信号，通过分析包络谱确定轴承的故障，实现了对滚动轴承的声学诊断。文献[10]针对声学信号信噪比低的问题，提出采用盲源分离技术与自适应 Morlet 小波变换的轴承声学诊断方法，能够有效地从强背景噪声下提取出轴承声学信号的故障特征。文献[11]针对轴承的声学诊断，提出一种结合自适应多尺度多结构形态滤波、小波阈值降噪和稀疏量分析的轴承故障特征提取方法，并验证了该方法的有效性。文献[12]利用声场全息术重建轴承工作时周围的声场，提出了一种滚动轴承故障诊断的声场分布特征提取方法。文献[13]将峭度与香农熵的比值做为优化指标，利用小波包变换和包络检测获得最佳带通滤波器，试验表明采用该方法能够有效地从背景噪声中提取到故障特征频率。

机器学习具有鲁棒性强、自动隔离噪声的特点，是轴承故障诊断的另一个重要研究方向。基于机器学习的故障诊断方法需要“特征–标签对”数据。轴承故障特征分为一维特征与二维特征。其中，一维特征往往为信号的统计特征，分为时域统计特征和频域统计特征 2 种，如方均根、方根幅值、峭度值、频谱质心等[14]；二维特征即图片数据，将信号的特征以图片的形式进行展示，常用的二维特征图有峭度图、波形图和时频图等[15-17]。对一维特征来说，目前常常采用的机器学习模型有支持向量机、K-近邻分类器、决策树、极限提升树和深度森林等。文献[18]以有效值、峰值和峭度值 3 个时域参数为输入，采用支持向量机分类器，实现了对滚动轴承的故障诊断。文献[19]采用多通道声学信号的时频域特征，结合卷积神经网络（CNN）实现了对齿轮箱的声学诊断。文献[20]采用声学信号的若干特征参数，使用支持向量机实现了滚动轴承的声学诊断。文献[21]采用电信号的多个时域特征、频域特征和时频域特征来表征滚动轴承的不同故障，采用随机森林分类器进行故障分类。该类方法容易受到人为主观干预的影响，特征的数量和种类容易导致故障诊断的性能不稳定。

深度学习是机器学习技术的新兴分支，具有模型小和运算资源需求少的优点。深度学习是基于图像数据的技术，因而故障特征的图像表达是基于深度学习的轴承声学故障诊断技术的核心和关键。卷积神经网络是深度学习的基础，现有的卷积神经网络架构有 LeNet-5、AlexNet 和残差网络等。文献[22] 采用声学信号的峭度图作为二维输入图像，参考 LeNet-5 神经网络架构，进行深层的特征提取，使用全连接层进行故障分类，取到了良好的表现。文献[23]基于 LeNet-5 网络构建故障诊断模型，以振动信号时间序列的灰度图作为输入，实现了对列车轴承的复合故障诊断。文献[24]采用小波时频图作为输入特征图，基于 AlexNet 网络构建故障诊断模型，实现了较高的故障诊断准确率。该类方法无需手动选择相关特征，模型会自动进行深层特征提取与故障诊断，但是发挥该类方法的优越性需要大量的数据样本量，对于少数故障样本的学习能力不强。

基于传统技术的轴承声学故障诊断技术和基于机器学习和振动信号的轴承故障诊断技术已有很多学者进行了相关研究，但是基于深度学习技术和声学信号的轴承声学故障诊断研究尚少。因此，针对故障轴承信号中噪声大、故障特征微弱的情况，本文研究将反映信号时频特性的小波时频图和反映信号周期性冲击特性的格拉姆角场图进行维度特征增广表达，并作为深度学习算法的输入特征，利用 ResNET18 卷积神经网络框架，构建电机轴承的深度学习故障识别模型，为电机轴承声学故障诊断提供全新的思路。

1　牵引电机轴承故障声学试验

1.1　试验平台组成

在消声室内组成牵引电机轴承故障声学试验台，部件组成如下：①高速列车牵引电机，功率625 kW，型号为YQ-625，最高转速为5 600 r/min；②4个麦克风；③利用电频控制器控制转速。试验平台如图1所示，4个麦克风构成4个同步的声音信号采集通道。

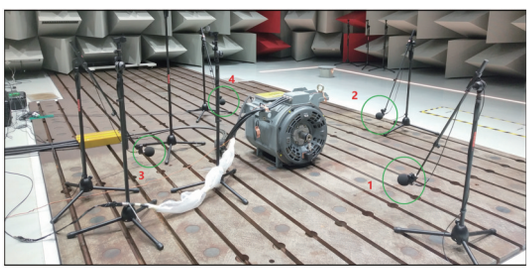


图1　试验平台

Fig. 1　Experimental platform

1.2　试验故障轴承

装在电机传动端的圆柱滚子轴承型号为NU214，轴承规格参数如表1所示。

表1　轴承规格表

Table 1　Bearing specification table

参数项目	参数值	参数项目	参数值
滚子个数	16	中径/mm	97.5
滚子直径/mm	13.0	外径/mm	125.0
滚子长度/mm	13.0	内径/mm	70.0
外滚道直径/mm	110.5	宽度/mm	23.0
内滚道直径/mm	84.5		

1.3　故障设置

采用电火花加工的方法产生单点损伤，损伤宽度为0.3 mm和1.5 mm，分别在轴承的保持架、内圈、外圈和滚子处产生轻度与重度损伤，共计8种故障。图2为外圈轻度故障轴承示意图，其余故障轴承汇总于图3。



图2　外圈轻度故障图

Fig. 2　Mild fault diagram of outer ring

1.4　试验过程

将加工过的故障轴承装入电机中，其他部件均保持为健康状况。将电子控制器控制电压频率设置为80.5 Hz，电机转速为2 414 r/min，模拟速度160 km/h的列车工况。采用图1所示的4个麦克风采集牵引电机工作时的声音，采样频率设置为54.94 kHz。收集8种轴承故障类型的牵引电机工作信号，采集到的数据量如表2所示。



图3　轴承故障种类汇总

Fig. 3　Summary of types of bearing faults

表2　数据统计

Table 2　Data statistics

故障类型	单通道采样时长/s	采样率/kHz	通道数	合计/s
保持架轻度故障	445	54.94	4	1 780
保持架重度故障	205	54.94	4	820
滚子轻度故障	445	54.94	4	1 780
滚子重度故障	205	54.94	4	820
内圈轻度故障	370	54.94	4	1 480
内圈重度故障	180	54.94	4	720
外圈轻度故障	205	54.94	4	820
外圈重度故障	195	54.94	4	780

2　基础理论

2.1　声学信号融合特征图

当轴承发生不同类型的故障时，其声学信号的频域组成会有所不同。对于不同的故障信号，其波形图之间会有细微的差别，其时域统计特征也会发生具有一定规律性的变化。常用的时域统计特征有方均根、峭度系数和裕度系数等，当噪声存在时，该类特征无法有效反映轴承的故障。为了兼顾时域特征与频域特征，提出将时域特征图与小波时频图进行叠加，达到

融合特征的效果。

为满足CNN的输入要求，需要将一维声学信号表征为二维图像。CNN在图像识别领域的性能极其优越，其性能依赖于以大量的二维图像作为输入。一般情况下，当样本数量足够多时，模型的分类表现会非常准确。

2.1.1 格拉姆角场(GAF)

计算机中图像是由多个通道的二维矩阵表达。为了充分利用CNN在图像识别领域的优势，首先将一维时间序列利用GAF转换为图像数据。GAF于2015年提出，其基本方法是将一维时序数据转化到极坐标系下，再使用三角函数生成GAF矩阵[25-26]。GAF矩阵不仅保留了时间序列的时间特性，而且突出了信号在时域内的特征，它的出现使得计算机视觉技术能够直接应用于时间序列的分类问题[27]。

假设给定牵引电机轴承故障的声学时间序列为$X=\{x_1,x_2,\cdots,x_n\}$，其时间戳为$\{t_1,t_2,\cdots,t_n\}$，求其GAF矩阵的过程如下：

①将时间序列X归一化到$[-1,1]$或$[0,1]$内，归一化公式为：

$$\bar{x}_{-1,1}^{i}=\frac{\left(x_i-\max(X)\right)+\left(x_i-\min(X)\right)}{\max(X)+\min(X)},\ i=1,2,\cdots,n \tag{1}$$

$$\bar{x}_{0,1}^{i}=\frac{x_i-\min(X)}{\max(X)-\min(X)} \tag{2}$$

本文将声学信号X归一化到$[-1,1]$中。

②求$\bar{x}_{-1,1}^{i}$的反余弦值，将该值作为极坐标系中的角度ϕ_i；以时间戳t_i与时间戳个数的比值作为极坐标系中的半径r，计算公式如下：

$$\left.\begin{aligned}\phi_i&=\arccos\left(\bar{x}_{-1,1}^{i}\right)\\ r&=\frac{t_i}{n}\end{aligned}\right\} \tag{3}$$

③利用任意2个时序点x_i、x_j的角度ϕ_i、ϕ_j之间的差或和的关系，通过和的余弦或差的正弦来定义2个时序点之间的时间相关性。根据向量内积的运算法则，利用角度的和或角度的差可定义2种GAF，分别为A_{GASF}和A_{GADF}。其中，A_{GASF}为

$$A_{\mathrm{GASF}}=\cos\left(\phi_i+\phi_j\right)=\cos\phi_i\cos\phi_j-\sin\phi\sin\phi_j \tag{4}$$

由步骤②可知，$\cos\phi=\bar{x}$且$\sin\phi=\sqrt{1-\left(\bar{x}\right)^2}$，那么

$$A_{\mathrm{GASF}}=\bar{x}^i\cdot\bar{x}^j-\sqrt{1-\left(\bar{x}^i\right)^2}\cdot\sqrt{1-\left(\bar{x}^j\right)^2} \tag{5}$$

同理，A_{GADF}为

$$A_{\mathrm{GADF}}=\sin\left(\phi_i+\phi_j\right)=\sin\phi_i\cos\phi_j-\cos\phi\sin\phi_j=\sqrt{1-\left(\bar{x}^i\right)^2}\cdot\bar{x}^j-\bar{x}^i\cdot\sqrt{1-\left(\bar{x}^j\right)^2} \tag{6}$$

④根据Gram矩阵的定义，本文使用A_{GADF}来定义矩阵$\boldsymbol{G}_{\mathrm{GADF}}$（简称$\boldsymbol{G}$矩阵），矩阵$\boldsymbol{G}_{\mathrm{GADF}}$为

$$\boldsymbol{G}_{\mathrm{GADF}}=\begin{bmatrix}\sin\left(\phi_1-\phi_1\right)&\sin\left(\phi_1-\phi_2\right)&\cdots&\sin\left(\phi_1-\phi_n\right)\\ \sin\left(\phi_2-\phi_1\right)&\sin\left(\phi_2-\phi_2\right)&\cdots&\sin\left(\phi_2-\phi_n\right)\\ \vdots&\vdots&\vdots&\vdots\\ \sin\left(\phi_n-\phi_1\right)&\sin\left(\phi_n-\phi_1\right)&\cdots&\sin\left(\phi_n-\phi_n\right)\end{bmatrix} \tag{7}$$

观察矩阵$\boldsymbol{G}_{\mathrm{GADF}}$内各元素的角标可知，矩阵左上角元素到右下角元素的时间戳依次增大。因此，该矩阵可以保留步骤③中所述的时间特性。原始时域信号的$\boldsymbol{G}_{\mathrm{GADF}}$矩阵的形成过程如图4所示。

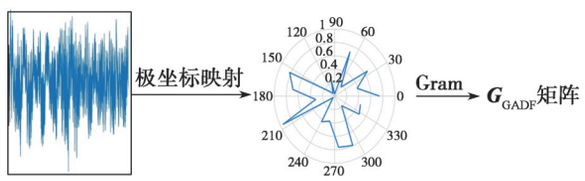


图4 $\boldsymbol{G}_{\mathrm{GADF}}$矩阵形成过程

Fig. 4 Formation process of $\boldsymbol{G}_{\mathrm{GADF}}$ matrix

⑤将$\boldsymbol{G}_{\mathrm{GADF}}$矩阵图形化表示如图5所示，该图像蕴含了原始时间序列的时域特征。由于$\boldsymbol{G}_{\mathrm{GADF}}$矩阵的尺寸与时间序列$X$的长度有关，为保证运算效率并避免尺寸太大导致图片占用的内存过多，将图像的像素数统一压缩为(224, 224)。

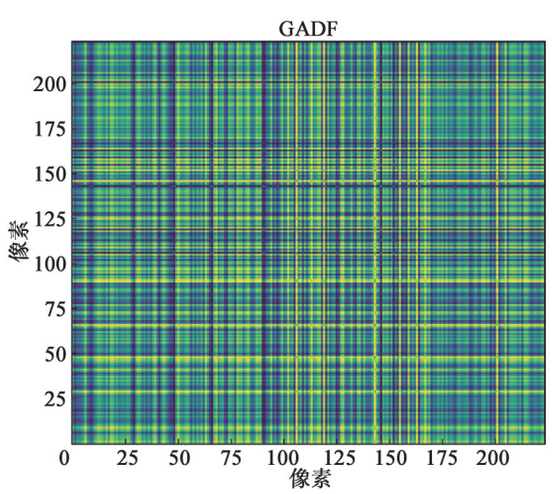


图5 GADF图

Fig. 5 GADF diagram

2.1.2 小波时频图

小波时频图可以反映信号随时间的推移而发生的频率组成变化，进而有效描述信号中细微的故障特征[28]。利用连续小波变换，选择复Morlet小波作为母函数生成声音信号的小波时频图，带宽参数和小波中心频率均取3，尺度序列长度取为256。以保持架轻度故障和重度故障为例，从采集到的信号中各截取1 s时长的信号，其小波时频图如图6和图7所示。小波时频图通过颜色的明暗反映各频率段成分的能量大小，颜色越亮代表该频段能量越大。

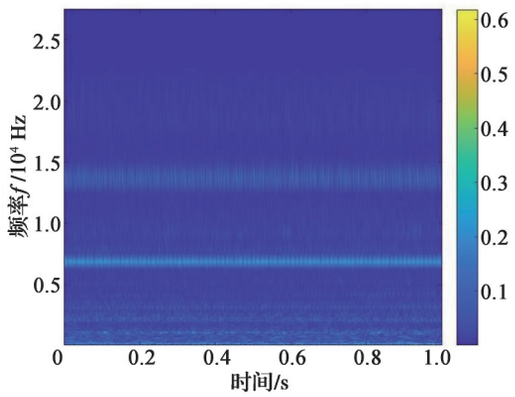


图 6　保持架轻度故障小波时频图

Fig. 6　Wavelet time-frequency map of mild fault of cage

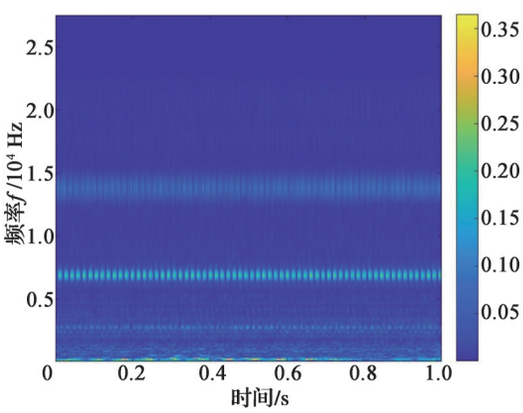


图 7　保持架重度故障小波时频图

Fig. 7　Wavelet time-frequency map of severe fault of cage

由图 6 与图 7 对比可知，当轴承故障类型不同时，牵引电机信号的频域内组成会有差别，各频率段的能量强度也不同，对应的小波时频图会有细微差别，难以用肉眼提取到其中的规律。为了便于融合特征，将小波时频图的像素尺寸调整为(224, 224)，即与 GADF 图相同。

2.2　特征图像融合

生成的 GADF 图与小波时频图都采用 JEPG 格式，JEPG 格式的图片是由红、绿、蓝 3 个通道构成，将它作为 CNN 的输入数据时，每个通道像素点上的值就是输入特征。一张 GADF 图或小波时频图的数据结构都为(3, 224, 224)，即它们由 RGB 3 个通道构成，每个通道数据结构都为(224, 224)，将 GADF 图与小波时频图重合叠放在一起，构成 6 通道的融合特征图。每张融合特征图的数据结构为(6, 224, 224)，融合过程如图 8 所示。时域特征或频域特征具有一定的片面性，无法有效地全面反映信号中的故障信息，融合特征图的维度越深，特征数量越多，同时包含了时域特征与频域特征，能够为 CNN 进行故障分类提供内容更丰富的判断依据。

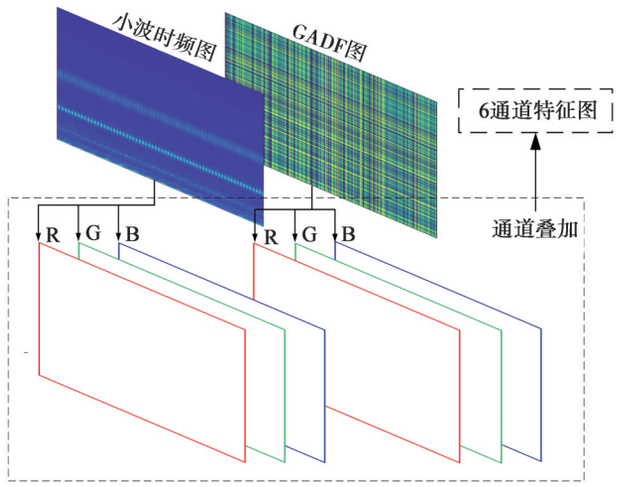


图 8　融合特征图

Fig. 8　Fusion feature map

2.3　卷积神经网络(CNN)

CNN 模型结构一般由输入层、卷积层、池化层、全连接层和输出层构成。通过将卷积层和池化层自由组合，可以构建性能各不相同的 CNN 架构。

输入数据为图像，经过输入层进入 CNN 网络中。卷积层作为 CNN 中最重要的组成部分，该层上的卷积核依次扫描每张特征图上的像素值，计算之后输出特征映射（Feature Map），卷积核的尺寸决定了特征映射的尺寸。池化层有最大池化、均值池化和中值池化等，其作用为对数据进行降维，并且能够防止过拟合，该层往往跟在卷积层后面。全连接层在整个 CNN 模型中能起到分类作用，全连接层的输出值经过输出层的 Softmax 分类器后得到输入数据的预测类别。

对于传统的 CNN 网络而言，其性能与网络的深度有直接关系，但随着深度的增加，容易导致以下问题：占用过多计算资源；容易导致过拟合；产生梯度消失或梯度爆炸问题。ResNET 的提出在一定程度上解决了深度带来的参数量过大的问题，并且能够有效避免梯度消失以及梯度爆炸的问题。ResNET 的核心在于使用残差单元，其思想为采用跳跃式连接，在卷积层外围将上一层的数据直接再次输入到下层，即将输入数据与单元输出相加，然后再用激活函数计算出输出，残差单元的细节如图 9 所示。

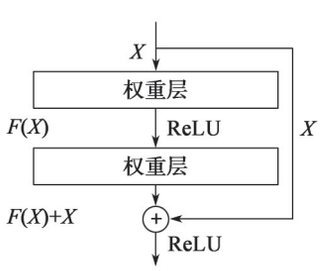


图 9　残差单元

Fig. 9　Residual unit

原始ResNET18网络架构包含17个卷积层、1个最大池化层、1个平均池化层和1个全连接层[29]。其中，除了第一个卷积层被用作数据预处理外，剩余的16个卷积层构成4个残差单元，每个单元中包含4个卷积层。原ResNET18模型如图10所示。

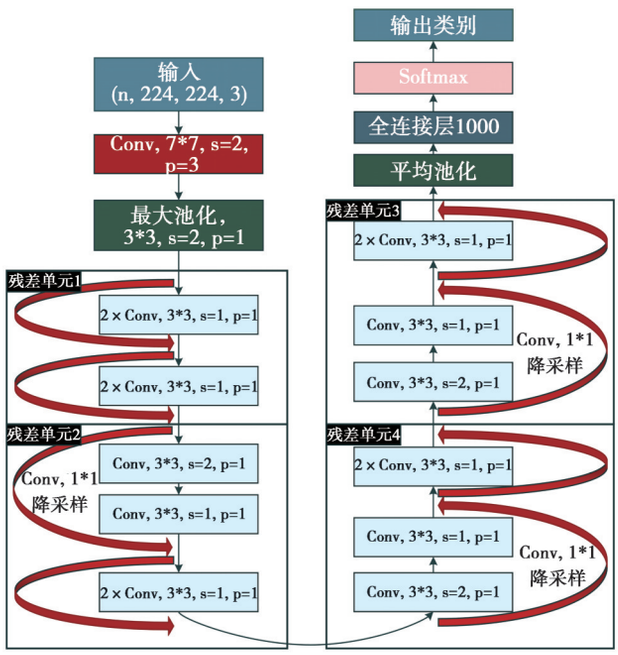


图10 ResNET18模型

Fig. 10 ResNET18 model

3 基于融合特征图的卷积故障诊断模型

3.1 技术思想

本文提出基于卷积神经网络（CNN），以声学信号的融合特征图作为输入数据集，实现轴承端对端的故障诊断。为充分提取并利用轴承声学信号中故障周期性冲击特征，基于格拉姆角场（GAF）的理论，将一维声学时间序列转为二维图像表示，并与反映故障信号时频特征的小波时频图进行维度增广融合，形成维度更深的融合特征图。将若干融合特征图作为特征样本，随机分割为训练集和测试集；在ResNET的基础上建立CNN模型；将训练集输入到模型中进行若干次拟合，得到ResNet轴承故障诊断模型；将测试集输入到模型中以监测模型的故障诊断效果。该方法的流程如图11所示。

3.2 ResNET18声学故障诊断模型

调整ResNET18声学故障诊断模型中输入层的卷积核数量，将其设置为6，从而建立适合6通道融合特征数据集的多分类声学诊断模型，使其可进行以融合特征图作为输入特征，实现轴承故障分类。全连接层依次设置为1 024，512，8，输出故障种类的概率分布，并通过Softmax分类器得出概率最大的故障种类。为了

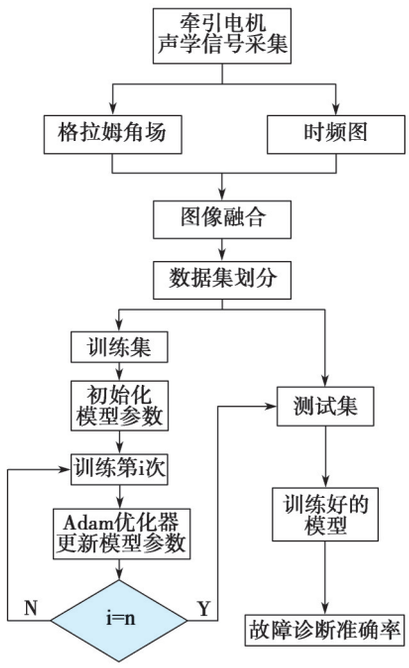


图11 技术思想

Fig. 11 Technical ideas

评估模型的拟合效果程度，计算其交叉熵损失（CrossEntropy Loss）。假设某个输入样本的真实标签为y_i，其被预测正确的概率为p_i（$0 \leqslant p_i \leqslant 1$），$p_i$为Softmax分类器返回的对应类别的值。该样本预测的交叉熵损失的计算公式为

$$L_i = -y_i \cdot \ln\left(p_i\right) \tag{8}$$

以所有样本的交叉熵损失之和作为模型的损失函数L，即

$$L = \sum L_i \tag{9}$$

以最小化损失函数为目标，采用Adam优化器对模型的权重参数进行优化。Adam优化器是一种自适应参数更新算法，该算法可以在模型优化过程中主动性地改变学习率的值，其优化流程如表3所示[30]。其中，

表3 Adam优化算法详细流程

Table 3 Detailed process of Adam optimization algorithm

Adam算法
①初始化参数：权重参数向量$\boldsymbol{\omega}_0$，时间步$t \leftarrow 0$，一阶矩向量$\boldsymbol{m}_0 \leftarrow 0$，二阶矩向量$\boldsymbol{v}_0 \leftarrow 0$
②while循环：当模型的$\boldsymbol{\omega}_t$没有达到收敛时
③时间步+1：$t \leftarrow t+1$
④更新权重ω的梯度：$\boldsymbol{g}_t \leftarrow \Delta_\theta f_t(\theta_{t-1})$
⑤更新偏差的一阶矩估计：$\boldsymbol{m}_t \leftarrow \beta_1 \cdot \boldsymbol{m}_{t-1} + (1-\beta_1) \cdot \boldsymbol{g}_t$
⑥更新偏差的二阶矩估计：$\boldsymbol{v}_t \leftarrow \beta_2 \cdot \boldsymbol{v}_{t-1} + (1-\beta_2) \cdot \boldsymbol{g}_t^2$
⑦计算偏差的修正一阶矩估计：$\hat{\boldsymbol{m}}_t \leftarrow \boldsymbol{m}_t / (1-\beta_1^t)$
⑧计算偏差的修正二阶矩估计：$\hat{\boldsymbol{v}}_t \leftarrow \boldsymbol{v}_t / (1-\beta_2^t)$
⑨更新权重参数：$\boldsymbol{\omega}_t \leftarrow \boldsymbol{\omega}_{t-1} - \alpha \cdot \hat{\boldsymbol{m}}_t / (\sqrt{\hat{\boldsymbol{v}}_t} + \varepsilon)$
⑩结束while循环
⑪返回最优权重参数$\boldsymbol{\omega}_t$

β_1, β_2 为指数衰减率；α 为初始学习率；ε 为非 0 常数，其作用为避免除数为 0 的情况。

对模型训练 45 次，每 15 次为 1 组，共训练 3 组。每次训练完毕时测试模型的分类准确率。每组训练中设置不同的学习率，刚开始为了使模型能够尽快收敛，学习率需要设置为一个较大的值，随着模型收敛程度的加深，学习率逐渐减小，以保证模型的稳定性并逐渐收敛到最佳。因此第 1 组至第 3 组训练过程的学习率分别设置为 α_1=0.001, α_2=0.000 1, α_3=0.000 01。整个训练过程中保持指数衰减率不变，分别设置为 β_1=0.9, β_2=0.999，常数 $\varepsilon=1\times10^{-8}$。

4　试验验证

4.1　构建数据集

采用数据增强的方法，基于固定采样间隔 Δt，以 t 秒为采样时长，将本试验采集的数据分割成若干个一维时间序列样本，实现显著增加样本量的目的。数据增强过程示意图如图 12 所示。假设采样数据共有 T 秒（T 为整数），经过数据增强后得到的样本数量 M 为

$$M=\frac{T-t}{\Delta t}+1 \tag{10}$$

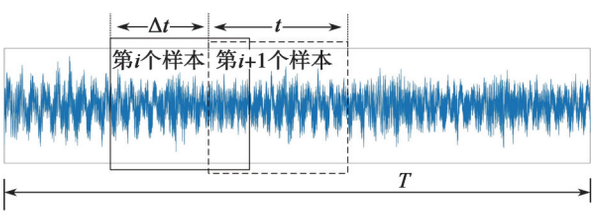


图 12　数据增强示意图

Fig. 12　Diagram of data enhancement

对本试验采集到的 8 种故障类型的 4 个通道信号进行切分，得到若干个长度为 1 s 的样本数据。取式(10)中 Δt=0.5 s, t=1 s，每个通道的样本数量为

$$M=\frac{T-1}{0.5}+1 \tag{11}$$

保持架轻度故障采样为例，采样时长为 T=445 s，则单个通道的样本数为

$$M=\frac{445-1}{0.5}+1=889 \tag{12}$$

该故障的样本总数为 3 556（$4\times M$），其余故障类型及样本总体情况如表 4 所示。

根据每个样本信号的 GADF 图与小波时频图，按照前文所述的方法，将这 2 个图片 RGB 通道的矩阵数据叠加，得到 6 通道的融合特征图。由表 4 可知，共得到 17 968 个融合特征图样本。以 7:3 的比例将总样本集随机分为训练集与测试集，其中训练集包含 12 578 张融合特征图，测试集包含 5 390 张融合特征图。数据集的数据结构表述为（样本数，长，宽，通道数），因此训练集数据结构为(12 578, 224, 224, 6)，测试集数据结构为(5 390, 224, 224, 6)。

采用独热编码（One-hot）对数据集制作标签，One-hot 编码打标签的方式为构建 1 组 1 个位置为 1，其余位置都为 0 的向量。本数据集的 One-hot 编码如表 5 所示。

表 4　样本数量汇总

Table 4　Summary of sample quantity

故障类型	单个样本长度/s	样本数
保持架轻度故障	1	3 556
保持架重度故障	1	1 636
滚子轻度故障	1	3 556
滚子重度故障	1	1 636
内圈轻度故障	1	2 956
内圈重度故障	1	1 436
外圈轻度故障	1	1 636
外圈重度故障	1	1 556
合计		17 968

表 5　One-hot 编码表

Table 5　One-hot encoding table

故障类型	One-hot 编码
保持架轻度故障	10000000
保持架重度故障	01000000
滚子轻度故障	00100000
滚子重度故障	00010000
内圈轻度故障	00001000
内圈重度故障	00000100
外圈轻度故障	00000010
外圈重度故障	00000001

4.2　试验结果分析

基于前文的样本集，进行 YQ-625 电机轴承故障声学诊断模型的训练和验证。为验证融合特征图卷积故障诊断模型的优越性，分别进行了以小波时频图、GADF 图、融合特征图为输入的 ResNET18 诊断模型的构建，并进行诊断准确率的对比分析。

3 组数据集的模型诊断结果如图 13~图 18 所示。其中，图 13~图 15 为模型的交叉熵损失值变化趋势，图 16~图 18 为模型的故障诊断准确率结果。随着训练次数的增加，模型的损失逐渐减小，模型的准确率逐渐增至最高。

由图 13~图 14 可知，单独以 GADF 图或小波时频图作为特征输入时，当模型对训练集的交叉熵损失达到最小时，测试集上的损失分别只能达到 45.701 047 和 31.091 692。由图 15 可知，当以融合特征图作为模型输入时，模型对测试集和训练集的拟合效果都很好，训练集上的损失达到最小时，测试集上的损失减小到了 0.368 093。

以测试集最终的准确率作为评判标准。由图 16~图 17 可知，随着模型对训练集的拟合，测试集的准确率

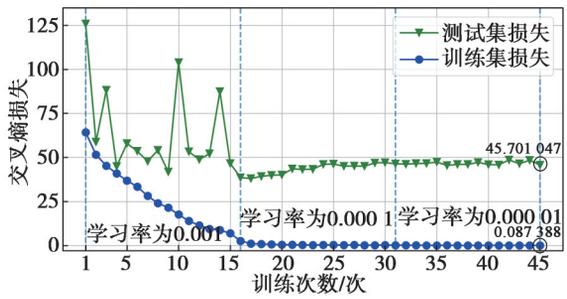


图 13　GADF 图数据集的模型损失

Fig. 13　Model loss of GADF graph dataset

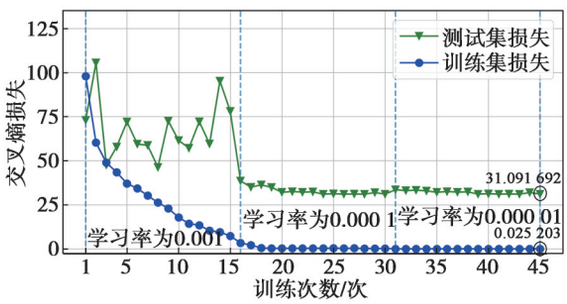


图 14　小波时频图数据集的模型损失

Fig. 14　Model loss of wavelet time-frequency map dataset

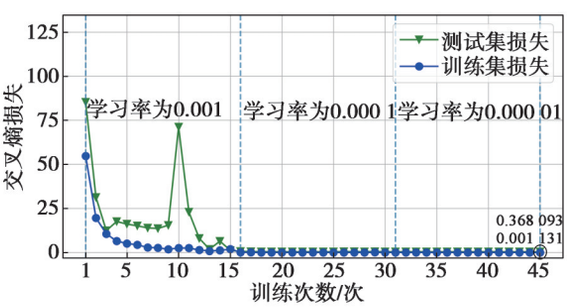


图 15　融合特征图数据集的模型损失

Fig. 15　Model loss of fusion feature map dataset

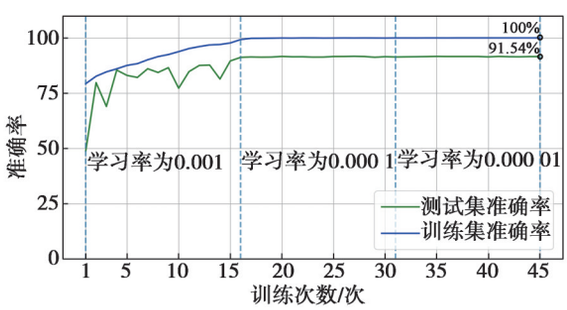


图 16　GADF 图数据集的准确率

Fig. 16　Accuracy of GADF graph dataset

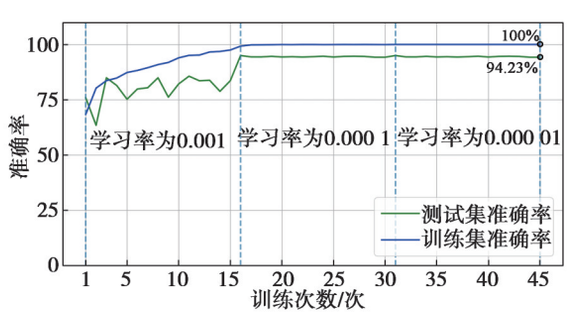


图 17　小波时频图数据集的准确率

Fig. 17　Accuracy of wavelet time-frequency map dataset

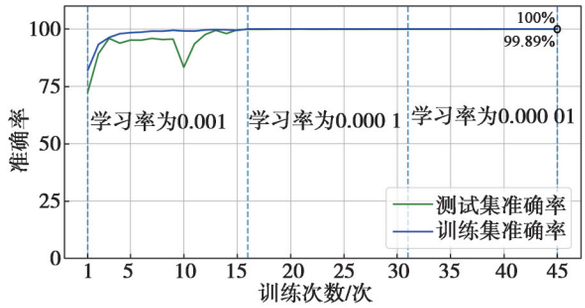


图 18　融合特征图数据集的准确率

Fig. 18　Accuracy of fusion feature map dataset

不断上升，当模型对训练集拟合完毕且准确率达到 100%时，GADF 图数据集和小波时频图数据集的测试集上的准确率分别为 91.54% 和 94.23%。由图 18 可知，模型对融合特征图的诊断准确率达到了 99.89%，具有极高的故障诊断可靠性。

5　结论

本文从特征融合的角度出发，提出特征图融合的方法，将轴承故障声学信号的 GADF 图和小波时频图进行叠加，得到更具故障特征价值的融合特征图。结合残差网络模型，以融合特征图作为输入数据，将其应用在轴承的声学故障诊断，通过试验得出以下结论：

①当分别以 GADF 图和小波时频图输入到残差网络中，分别取得了 91.54% 和 94.23% 的准确率。

②当以融合特征图作为输入时，取得了 99.89% 的准确率，故障诊断的可靠度有了较大的提升，证明本文提出的方法行之有效。

参考文献：

[1] DING Xiaoxi, LI Yulan, XIAO Jiawei, et al. Parametric doppler correction analysis for wayside acoustic bearing fault diagnosis[J]. Mechanical Systems and Signal Processing, 2022, 166: 108375.

[2] 李琛, 徐彦伟, 颉潭成, 等. 基于 FFT-SDAE 的地铁牵引电机轴承故障智能诊断[J]. 现代制造工程, 2021(11): 155-161.
LI Chen, XU Yanwei, JIE Tancheng, et al. Intelligent diagnosis of subway traction motor bearing fault based on FFT-SDAE[J]. Modern Manufacturing Engineering, 2021(11): 155-161.

[3] LI Guozheng, TANG Gang, LUO Ganggang, et al. Underdetermined blind separation of bearing faults in hyperplane space with variational mode decomposition[J]. Mechanical Systems and Signal Processing, 2019, 120: 83-97.

[4] 朱文龙, 杨家伟, 关照议, 等. 牵引电机轴承故障诊断技术综述[J]. 控制与信息技术, 2021(5): 12-19.
ZHU Wenlong, YANG Jiawei, GUAN Zhaoyi, et al. Overview of traction motor bearing fault diagnosis technology

[J]. Control and Information Technology, 2021(5): 12-19.

[5] 龙磊, 何兵, 刘方, 等. 基于KJADE的列车轴承轨边声学诊断方法研究[J]. 振动、测试与诊断, 2020, 40(4): 781-787.
LONG Lei, HE Bing, LIU Fang, et al. Fault diagnosis of locomotive bearings using wayside acoustic signals based on KJADE[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(4): 781-787.

[6] HE Qingbo, WANG Jun, HU Fei, et al. Wayside acoustic diagnosis of defective train bearings based on signal resampling and information enhancement[J]. Journal of Sound and Vibration, 2013, 332(21): 5635-5649.

[7] ZHANG Dingcheng, ENTEZAMI M, STEWART E, et al. Adaptive fault feature extraction from wayside acoustic signals from train bearings[J]. Journal of Sound and Vibration, 2018, 425: 221-238.

[8] 周俊, 伍星, 迟毅林, 等. 盲解卷积和频域压缩感知在轴承复合故障声学诊断的应用[J]. 机械工程学报, 2016, 52(3): 63-70.
ZHOU Jun, WU Xing, CHI Yilin, et al. Blind deconvolution and frequency domain compressive sensing application in bearing composite acoustic fault diagnosis[J]. Journal of Mechanical Engineering, 2016, 52(3): 63-70.

[9] 于功也, 马波, 闫戈. 基于共振稀疏分解与子带增强的滚动轴承声学诊断方法[J]. 北京化工大学学报(自然科学版), 2021, 48(1): 49-57.
YU Gongye, MA Bo, YAN Ge. Acoustic diagnosis of a rolling bearing based on resonance sparse decomposition and sub-band enhancement[J]. Journal of Beijing University of Chemical Technology (Natural Science Edition), 2021, 48 (1): 49-57.

[10] 李静娇, 陈恩利, 刘永强. BSS与Morlet小波变换在轴承声学故障诊断中的研究[J]. 机械强度, 2018, 40(3): 528-533.
LI Jingjiao, CHEN Enli, LIU Yongqiang. Feature extraction method of sound signal to rolling bearing based on blind source separation and Morlet wavelet[J]. Journal of Mechanical Strength, 2018, 40(3): 528-533.

[11] 樊高瞻, 周俊, 朱昆莉. 基于改进形态-小波阈值降噪的轴承复合故障声学诊断[J]. 振动与冲击, 2020, 39(12): 221-226.
FAN Gaozhan, ZHOU Jun, ZHU Kunli. An improved morphological-wavelet threshold de-noising method based acoustic diagnosis for bearing composite faults[J]. Journal of Vibration and Shock, 2020, 39(12): 221-226.

[12] 鲁文波, 蒋伟康. 利用声场空间分布特征诊断滚动轴承故障[J]. 机械工程学报, 2012, 48(13): 68-72.
LU Wenbo, JIANG Weikang. Diagnosing rolling bearing faults using spatial distribution features of sound field[J]. Journal of Mechanical Engineering, 2012, 48(13): 68-72.

[13] HEMMATI F, ORFALI W, GADALA M S. Roller bearing acoustic signature extraction by wavelet packet transform, applications in fault detection and size estimation[J]. Applied Acoustics, 2016, 104: 101-118.

[14] 陈阳, 李一, 姬正一, 等. 基于振动时域特征的船用滚动轴承故障诊断方法[J]. 机床与液压, 2021, 49(14): 193-200.
CHEN Yang, LI Yi, JI Zhengyi, et al. Fault diagnosis method for marine rolling bearings based on vibration time domain characteristics[J]. Machine Tool & Hydraulics, 2021, 49(14): 193-200.

[15] 迭旭鹏, 康建设, 池阔. 基于变分模态分解与快速谱峭图的齿轮箱滚动轴承故障特征提取[J]. 机械传动, 2020, 44 (1): 143-149.
DIE Xupeng, KANG Jianshe, CHI Kuo. Fault feature extraction of gearbox rolling bearing based on VMD and fast-kurtogram[J]. Journal of Mechanical Transmission, 2020, 44 (1): 143-149.

[16] 张龙, 徐天鹏, 王朝兵, 等. 基于改进谱峭度与一维卷积神经网络的轴承故障诊断[J]. 机械设计与研究, 2021, 37(4): 99-105.
ZHANG Long, XU Tianpeng, WANG Chaobing, et al. Bearing fault diagnosis based on an improved kurtogram kurtosis and one-dimensional convolution neural network[J]. Machine Design & Research, 2021, 37(4): 99-105.

[17] 亓海征, 殷海双. 基于时频图的改进LeNet-5网络轴承故障诊断[J]. 机械设计与制造工程, 2021, 50(10): 54-58.
QI Haizheng, YIN Haishuang. Improved LeNet-5 network bearing fault diagnosis based on time-frequency diagram[J]. Machine Design and Manufacturing Engineering, 2021, 50 (10): 54-58.

[18] 郝勇, 吴文辉, 商庆园. 基于变分模态分解和支持向量机的滚动轴承品质评估[J]. 控制理论与应用, 2020, 37(7): 1544-1551.
HAO Yong, WU Wenhui, SHANG Qingyuan. Rolling bearing quality evaluation based on variational mode decomposition and support vector machines[J]. Control Theory & Applications, 2020, 37(7): 1544-1551.

[19] 李少波, 姚勇, 桂桂, 等. 基于CNN与多通道声学信号的齿轮故障诊断[J]. 中国测试, 2019, 45(10): 1-5.
LI Shaobo, YAO Yong, GUI Gui, et al. Gear fault diagnosis based on CNN and multi-channel acoustic signals[J]. China Measurement & Test, 2019, 45(10): 1-5.

[20] 唐刚, 秦朝任. 基于声学信号瓶颈特征的滚动轴承故障诊断[J]. 复旦学报(自然科学版), 2020, 59(3): 293-298.
TANG Gang, QIN Chaoren. Rolling bearing fault diagnosis based on bottleneck characteristics of acoustic signal[J]. Journal of Fudan University (Natural Science), 2020, 59(3): 293-298.

[21] 王兰兰, 朱捷, 周正平, 等. 基于随机森林的滚动轴承故障辨识方法研究[J]. 机电工程, 2021, 38(12): 1599-1604.
WANG Lanlan, ZHU Jie, ZHOU Zhengping, et al. Fault identification method of rolling bearing based on random forest[J]. Journal of Mechanical & Electrical Engineering, 2021, 38(12): 1599-1604.

[22] PROSVIRIN A, KIM J, KIM J M. Bearing fault diagnosis based on convolutional neural networks with kurtogram representation of acoustic emission signals[C]//Springer. Advances in Computer Science and Ubiquitous Computing. Singapore: Springer, 2018: 21-26.

[23] 姚德臣, 刘恒畅, 杨建伟, 等. 基于深度学习的城轨列车轴承复合故障诊断研究[J]. 铁道学报, 2021, 43(6): 37-44.
YAO Dechen, LIU Hengchang, YANG Jianwei, et al. Diagnosis of compound faults of bearings of urban rail train based on deep learning model[J]. Journal of the China Railway Society, 2021, 43(6): 37-44.

[24] 鄢仁武, 林穿, 高硕勋, 等. 基于小波时频图和卷积神经网络的断路器故障诊断分析[J]. 振动与冲击, 2020, 39(10): 198-205.
YAN Renwu, LIN Chuan, GAO Shuoxun, et al. Fault diagnosis and analysis of circuit breaker based on wavelet time-frequency representations and convolution neural network [J]. Journal of Vibration and Shock, 2020, 39(10): 198-205.

[25] 仝钰, 庞新宇, 魏子涵. 基于GADF-CNN的滚动轴承故障诊断方法[J]. 振动与冲击, 2021, 40(5): 247-253.
TONG Yu, PANG Xinyu, WEI Zihan. Fault diagnosis method of rolling bearing based on GADF-CNN[J]. Journal of Vibration and Shock, 2021, 40(5): 247-253.

[26] WANG Zhiguang, OATES T. Imaging time-series to improve classification and imputation[C]//AAAI Press. Proceedings of the 24th International Conference on Artificial Intelligence. Buenos Aires: AAAI Press, 2015: 3939-3945.

[27] 庞新宇, 仝钰, 魏子涵. 一种GAF-CNN行星齿轮箱故障诊断方法[J]. 北京理工大学学报, 2020, 40(11): 1161-1167.
PANG Xinyu, TONG Yu, WEI Zihan. A fault diagnosis method for planetary gearbox based on GAF-CNN[J]. Transactions of Beijing Institute of Technology, 2020, 40 (11): 1161-1167.

[28] 袁建虎, 韩涛, 唐建, 等. 基于小波时频图和CNN的滚动轴承智能故障诊断方法[J]. 机械设计与研究, 2017, 33(2): 93-97.
YUAN Jianhu, HAN Tao, TANG Jian, et al. An approach to intelligent fault diagnosis of rolling bearing using wavelet time-frequency representations and CNN[J]. Machine Design & Research, 2017, 33(2): 93-97.

[29] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//IEEE. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778.

[30] KINGMA D P, BA J. Adam: a method for stochastic optimization[DB/OL]. (2017-01-30) [2022-12-16]. https://arxiv.org/abs/1412.6980.

收稿日期：2023-02-13