DOI：10.13890/j.issn.1000-128X.2023.06.005　　文章编号：1000-128X(2023)06-0039-10

基于双通道特征融合的轴承故障诊断方法

张晓宁[1]，朱慧龙[1]，辛　亮[1]，杨慕晨[1]，汪　浩[2]
（1.中车青岛四方机车车辆股份有限公司，山东 青岛　266111；
2.西南交通大学 轨道交通运载系统全国重点实验室，四川 成都　610031）

摘　要：基于卷积神经网络（Convolution Neural Network，CNN）的智能诊断方法在轴承故障诊断中应用广泛，但是大多数诊断模型以单源信息输入为主，这将影响基于CNN的故障诊断准确性和可靠性。针对这个问题，文章提出一种基于双通道特征融合的滚动轴承故障诊断方法。首先利用多重Q因子连续Gabor小波变换（Multiple Q-factor Continuous Gabor Wavelet Transform，CMQGWT）和快速谱相干（Fast Spectral Coherence，Fast-SC）分别构造滚动轴承振动信号的时频分析图；然后搭建1个具有双输入通道的CNN网络模型，通过特征融合层将各个通道提取的深度时频特征融合成1个新的特征；最后利用分类器输出诊断结果。在高速列车滚动轴承单故障和复合故障的分类识别试验中，较之于单输入通道的CNN模型，该模型具有更高的诊断准确性和鲁棒性。

关键词：滚动轴承；卷积神经网络；特征融合；故障诊断；高速列车
中图分类号：TH133.3；U292.91+4　　**文献标识码：**A

Bearing fault diagnosis method based on dual-channel feature fusion

ZHANG Xiaoning[1], ZHU Huilong[1], XIN Liang[1], YANG Muchen[1], WANG Hao[2]

(1. CRRC Qingdao Sifang Co., Ltd., Qingdao, Shandong 266111, China; 2. State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu, Sichuan 610031, China)

Abstract: Intelligent diagnosis method based on convolution neural network (CNN) has been widely used in bearing fault diagnosis. However, most existing diagnostic models rely on single-source information inputs, limiting their accuracy and reliability. To solve this limitation, this paper presents a rolling bearing fault diagnosis method based on dual-channel feature fusion. Firstly, the time-frequency analysis diagrams of rolling bearing vibration signals were constructed by using multiple Q-factor continuous Gabor wavelet transform (CMQGWT) and fast spectral coherence (Fast-SC), respectively. Subsequently, a CNN model with dual input channels was constructed, allowing for the fusion of deep time-frequency features extracted from each channel into a new feature at a feature fusion layer. Finally, the diagnosis results were output using a classifier. Through classification and recognition experiments involving single and compound faults in rolling bearings for high-speed trains, compared with the CNN model with a single input channel, the proposed model demonstrates superior diagnostic accuracy and robustness.

Keywords: rolling bearing; convolution neural network; feature fusion; fault diagnosis; high-speed train

0　引言

滚动轴承是高速列车走行部的关键旋转部件，其作用是支撑轮对的旋转，使列车沿轨道方向运动。由于长期复杂严苛的工作环境，滚动轴承容易发生局部缺陷，一旦轴承发生失效，可能导致严重的人员伤亡事故和经济损失[1]。因此，为了保证列车运行稳定性和

基金项目：四川省自然科学基金项目（2022NSFSC1918，2022NSFSC1910）
通信作者：汪　浩（1997—），男，硕士研究生，主要从事机车车辆测控技术研究和故障诊断；E–mail: wh15223389523@163.com
引用格式：张晓宁, 朱慧龙, 辛亮, 等. 基于双通道特征融合的轴承故障诊断方法[J]. 机车电传动, 2023(6): 39-48.
Citation: ZHANG Xiaoning, ZHU Huilong, XIN Liang, et al. Bearing fault diagnosis method based on dual-channel feature fusion[J]. Electric drive for locomotives,2023(6): 39-48.

安全性，对轴承进行状态监测和早期故障诊断具有重要意义。

轴承故障诊断方法通常包含特征提取和模式识别[2]。随着人工智能技术的发展，利用机器学习实现轴承故障诊断成为近年的研究热点，受到广大学者的青睐。传统机器学习方法（如人工神经网络）、支持向量机等对小数据集的分类诊断效果较好，但是特征提取过程需要专家经验的参与，而且与模式识别步骤彼此孤立，自学习能力较弱[3-4]。深度学习作为机器学习的一个分支，与基于传统机器学习算法的浅层诊断模型相比，它能自动提取数据源的关键特征，避免特征提取环节对专家经验的依赖，具有自适应学习海量数据的能力[5]。

卷积神经网络（Convolution Neural Network，CNN）作为深度学习中的典型网络，因其强大的特征学习能力已被广泛应用于旋转机械故障诊断领域。文献[6]利用短时傅里叶变换得到的二维时频谱作为CNN模型输入，实现频谱中不同故障特征自适应提取和分类；文献[7]利用经验模态分解算法对振动信号进行分析和处理，然后将所得结果和原信号合成二维张量，并导入CNN模型实现轴承故障诊断。文献[8]利用小波包能量图作为CNN模型的输入，可以有效实现在负载波动场景下的多种故障分类。上述方法都采用了信号分析算法来获取诊断模型的数据输入，取得了不错的效果，但由于各信号分析算法的原理、特点和优势不同，因此具有不同的缺陷，这使得故障信号的部分特征丢失，不能进入网络训练，导致单一数据源输入CNN模型的分析效果在进行轴承故障分类时受到限制。如何综合利用多种数据源，构建一种多通道输入的CNN模型算法，以克服单通道数据源输入CNN模型的缺陷，提高轴承故障诊断的可靠性和准确性，是一个值得研究的课题。信息融合理论最初被提出并应用于军事监测领域[9]，随着该技术的发展，研究学者将其拓展到滚动轴承旋转机械设备的故障诊断领域[10-12]。它可以将不同的数据源按照某一融合层次（数据级、特征级或决策级）根据一定的规则进行综合优化和自动分析，从而实现比单一数据源输入的网络模型更为精确的故障模式识别。

针对上述客观存在的问题，本文提出了一种基于双通道特征融合的轴承故障诊断方法，搭建了具有双输入通道的CNN网络模型，通过在网络结构中添加特征融合层，将单个CNN通道提取的时频特征融合成一个新的特征，以综合利用单个通道提取特征的优势，并根据融合后的深度时频特征进行故障模式识别；同时，分别采用单通道的CNN模型对滚动轴承不同故障类型进行分类识别，以验证本文方法的鲁棒性和准确性。

1 双通道数据集构造

有效的故障数据集获取是利用CNN模型进行故障诊断的重要步骤。多重Q因子连续Gabor小波变换（Multiple Q-factor Continuous Gabor Wavelet Transform，CMQGWT）是一种改进连续小波变换方法[13]，能够对信号进行时频域分析，并输出时频分析图像，具有时间和频率分辨率高的优点，但它仍然具有小波变换类方法的不足，如小波基函数的选择依赖于人工经验等问题。快速谱相干（Fast Spectral Coherence，Fast-SC）作为一种循环平稳分析方法，能够解调信号，并表征调制信号和载波信号的整体结构，具有同时揭示故障信号的特征频率和共振频率的能力，但有学者研究发现信号中的噪声成分会影响Fast-SC的分析效果[14]。基于上述讨论，单通道的CNN模型由于数据源获取方法本身存在缺陷，导致诊断效果受到限制，因此考虑结合CMQGWT和Fast-SC算法的各自优势，分别利用二者对信号进行时频域分析，并生成对应的时频分析图像：通道1的输入数据源是经过CMQGWT处理的小波时频图；通道2的输入数据源是利用Fast-SC方法生成的循环谱相干图。随后搭建双通道CNN网络模型，提取、融合各个通道的数据特征。

2 卷积神经网络

卷积神经网络作为深度学习的代表性框架之一，是一种集特征提取和故障分类于一体的典型前馈式神经网络。LeNet-5[15]作为经典的CNN模型，其结构如图1所示，主要包括7层网络结构（不含输入层），其中包括3个卷积层和激励层、2个池化层、1个全连接层和1个输出层，各层基本参数如表1所示。

表1 LeNet-5模型基本参数

Table 1 Basic parameters of LeNet-5 model

网络层	大小	数量
卷积层C1	5×5	6
最大池化层S2	2×2	6
卷积层C3	5×5	16
最大池化层S4	2×2	16
卷积层C5	5×5	16
全连接层F6	120	1
输出层	84	1

2.1 卷积层和激励层

卷积层和激励层通常作为一个整体，是CNN模型的核心部分。首先，卷积层通过卷积核对上一层的输出特征进行反复局部卷积运算；然后，利用激活函数对上一步的卷积结果进行非线性变换，生成一系列特

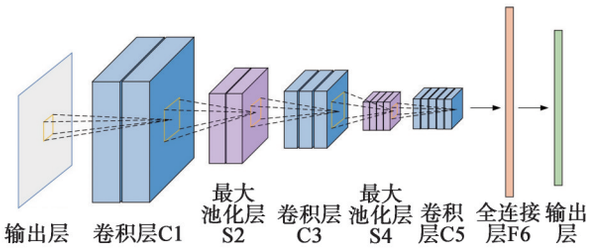

图 1　LeNet-5 网络结构

Fig. 1　LeNet-5 network structure

征图，并且将学习到的特征信息提取到下一层。整个过程的数学表达式为

$$p=f(x_{i+1})=f(W_i*x_i+b_i) \tag{1}$$

式中：$*$ 为卷积运算符；x_i 为输入当前层的特征图；x_{i+1} 为经过卷积计算后输出的特征图；W_i 为卷积核的权重系数；b_i 为偏置；p 为经过激活运算后得到的特征图；$f(\cdot)$ 为激活函数。

常见的激活函数有 TanH, Sigmoid , ReLU 等[16]，其中 ReLU 函数能够有效避免反向传播中出现梯度消失的问题。在本文中的试验部分，选用 ReLU 函数作为卷积的激活函数，其数学形式为

$$f(x)=\begin{cases}x, & x>0\\ 0, & x\leqslant 0\end{cases} \tag{2}$$

2.2　池化层

池化层也叫下采样层，是一种添加于 2 个卷积层之间的网络结构，如图 2 所示。它能够对卷积后的特征图进行压缩和降维，降低数据计算量，增强模型泛化能力，防止模型过拟合[17]。常见的池化方法包括平均值池化和最大值池化。

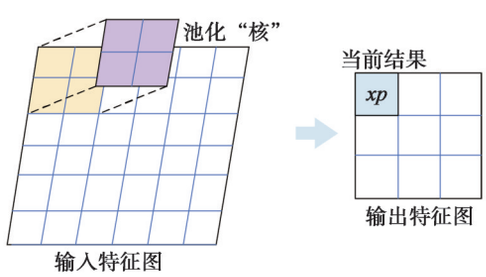

图 2　池化层示意图

Fig. 2　Schematic diagram of pooling layer

2.3　全连接层

全连接层的功能是把经过多次卷积和池化后的数据特征映射成最终结果。首先，将前一步骤输出的特征图平铺为一维向量；然后，使用激活函数完成最终的识别分类，如图 3 所示，其函数表达式为

$$\boldsymbol{o}=F(w\boldsymbol{x}+b) \tag{3}$$

式中：$\boldsymbol{o}$ 为全连接层的输出张量；$F(\cdot)$ 为激活函数，本文使用 Softmax 函数；w 为全连接层的权重系数；$\boldsymbol{x}$ 为来自上一层的输入张量；b 为偏置。

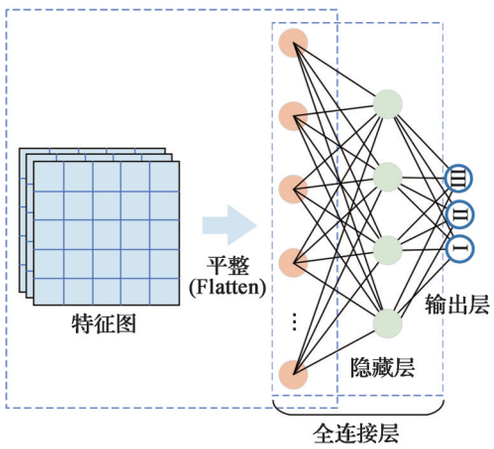

图 3　全连接层示意图

Fig. 3　Schematic diagram of fully connected layer

3　本文方法

为了提升单一数据源输入的 CNN 故障诊断模型的准确率和可靠性，将 CMQGWT 和 Fast-SC 理论应用于 CNN 模型构建，并结合信息融合理论将多通道提取的深度时频特征融合成一个特征，从而利用每个通道提取特征的优势互补，最终得到准确性和鲁棒性更好的诊断结果。

3.1　双输入通道的 CNN 模型

本文参考了 CNN 的经典模型 LeNet-5，在此基础上提出了一种双输入通道的 CNN 模型。首先，在第一个卷积层之前增加 1 个平均池化层，通过下采样达到压缩数据、减少计算量和加快训练速度的目的；然后，依次使用 2 个“卷积+池化”模块，再使用 1 个卷积层对特征进行深度提取，在每个卷积层后均添加 1 个批量归一化层，以避免梯度消失问题，并采用 ReLU 函数作为激活函数。由于所提模型需要输入 2 个图像数据源，因此重复上述操作生成 2 个通道，利用融合层将每个单通道的深度特征进行融合，并且通过 Softmax 分类器来实现诊断结果的输出。

根据上述步骤，生成具有双输入通道的二维 CNN 模型，模型主要由 3 个卷积层、2 个池化层、1 个平整层、1 个融合层、1 个全连接层和 1 个分类层组成，网络的参数确定参考文献[7]和文献[18]，模型具体结构如图 4 所示。

3.2　模型诊断流程

双输入通道的 CNN 模型具有多源深度特征提取和融合能力，模型诊断流程如图 5 所示，具体实施步骤如下：

①获取高速列车滚动轴承振动信号的数据样本；

②分别利用 CMQGWT 和 Fast-SC 算法对样本数据

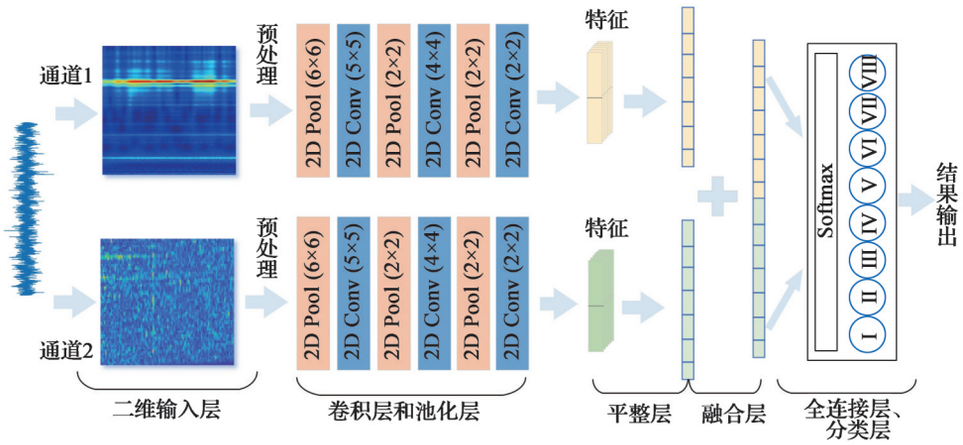

图4 双输入通道的CNN模型

Fig. 4 CNN model with dual input channels

进行分析和处理，分别生成各数据样本的连续小波时频图和循环谱相干图，并通过随机划分的方式构建训练集和测试集；

③搭建特征融合CNN模型，确定模型结构参数、最大训练轮数、参数优化算法、学习率等；

④将训练集输入步骤③中搭建的模型进行训练，通过多次迭代优化模型参数，直至模型满足所需精度要求；

⑤将测试集输入训练好的模型，输出故障诊断结果，评估模型精度。

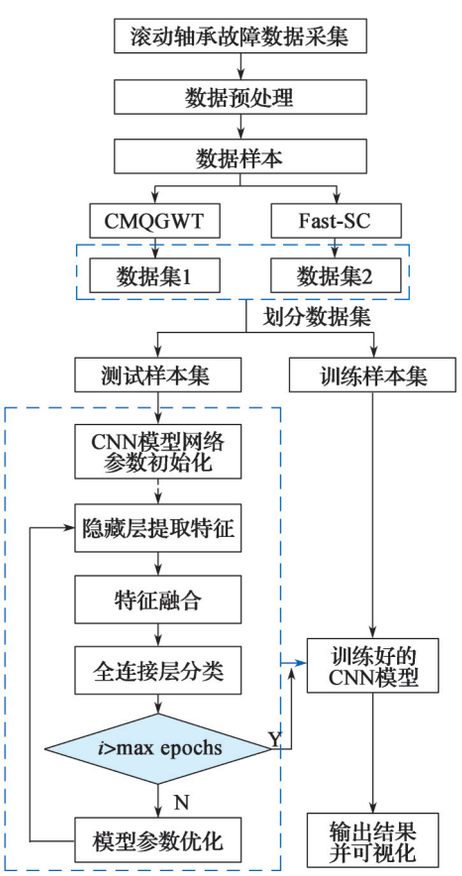

图5 基于双输入通道的CNN模型诊断流程

Fig. 5 Diagnosis process based on CNN model with dual input channels

4 试验验证

4.1 台架试验

为了验证本文所提方法的有效性，针对高速列车滚动轴承常见的外圈故障、保持架故障、滚动体故障、复合故障，以及正常轴承等7种状态进行模拟试验。试验数据来源于CRH2型高速列车轮对的跑合试验台，该试验台模拟完整的“轮对–轴承”和驱动系统，主要由牵引电机、驱动轮、试验轮对、轴箱、轴承、加载装置等系统部件组成，整体结构如图6所示。驱动子系统由电机和驱动轮组成，驱动轮将牵引力传递给轮对。试验使用的加速度计为三轴应变式加速度计，可以测量结构在水平方向、纵向和垂直方向的振动，采样频率为10 kHz。

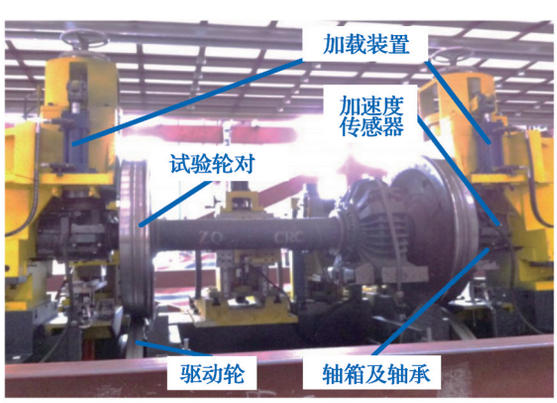

图6 轮对轴承试验台

Fig. 6 Wheelset bearing test bed

试验采用密封型双列圆锥滚子轴承，轴承型号为CRI-2962。设置试验台的模拟速度为100 km/h，获取该速度级下7种状态的轴承振动信号，包括外圈、保持架、滚动体3种类型的人工伤，具体如表2所示。具体来讲，在轴承1外圈内表面设置深度为1 mm的烧蚀凹痕；在轴承2的2个滚动体之间设置保持架断裂故障；在轴承3滚动体上设置深度为1 mm纵向烧蚀凹痕，如

图 7 所示。

表 2　试验轴承状态

Table 2　Bearing state in experiments

轴承状态	外圈故障	保持架故障	滚动体故障
1	√		
2		√	
3			√
4	√	√	√
5	√	√	
6	√		√
7			

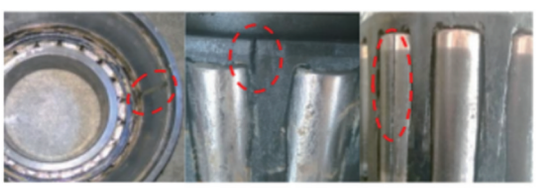

图 7　轴承人工伤位置

Fig.7　Location of artificial damage on bearing

4.2　构造样本

为获取更多的训练样本以增强模型的泛化能力，采用如图 8 所示的滑动取样法对上述 7 种轴承状态的振动信号进行数据重采样，对于离散数据而言，设置滑动步长为 1 500 个点，样本长度为 3 000 个点，依次对各信号进行截取，从而产生每种轴承状态下的 98 个数据样本，共计获得 7 种状态的 686 个数据样本。

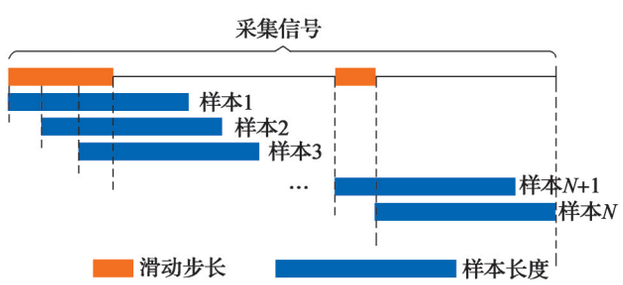

图 8　滑动取样法

Fig. 8　Sliding sampling method

分别利用 CMQGWT 和 Fast-SC 算法生成所有数据样本的小波时频图和循环谱相干图。为了提升计算速度和降低计算成本，对上述图像进行去坐标、去文字、灰度处理和无损尺寸压缩等预处理。最后，得到全部数据样本的 2 类时频图，并通过随机变换抽取方式得到 5 组不同的训练集和测试集，其中训练集和测试集按照 7:3 的比例随机划分，数据结构如表 3 所示。

以轴承状态“1”“4”“5”“6”的数据样本为例，按上述方法进行处理，得到如图 9 和图 10 所示的对应时频图。从图 9 和图 10 可知，这 2 类时频分析方法可以从不同角度描述轴承振动信号的细微故障特征。其中，在图 9 中均存在 50 Hz 及其倍频的工频干扰，这是由于试验台使用了交流电机进而引入了工频干扰，试验台基础振动频率 216 Hz 在小波时频图中也有所体现，而故障特征频率成分在高幅值的工频和基础振动频率干扰下显得相对微弱；在图 10 中轴承状态“4”“6”的共振频率和故障循环频率良好呈现，而轴承状态“1”“5”的振动信号由于受噪声的影响，其故障信息未能有效表征。因此，仅依据任意两者之一的时频分析图

表 3　数据结构

Table 3　Data structure

数据源	图片大小	训练集数量	测试集数量
CMQGWT	200×200	483	203
Fast-SC	200×200	483	203

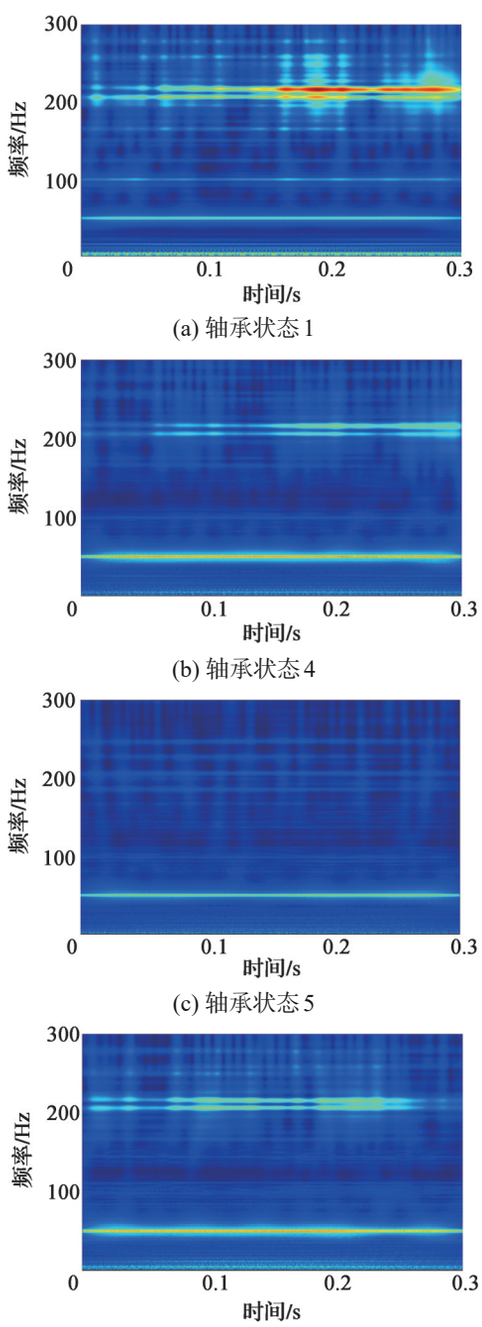

(a) 轴承状态 1

(b) 轴承状态 4

(c) 轴承状态 5

(d) 轴承状态 6

图 9　基于 CMQGWT 的小波时频图

Fig. 9　Wavelet time-frequency diagrams based on CMQGWT

像均难以直接识别轴承故障特征。

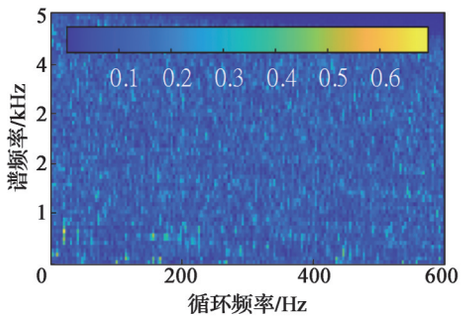

(a) 轴承状态 1

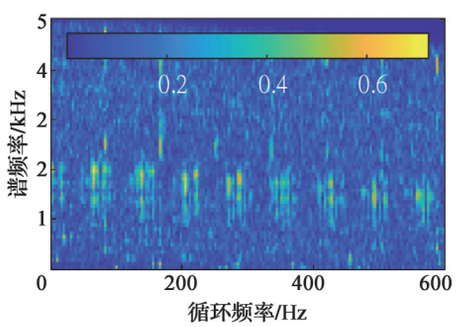

(b) 轴承状态 4

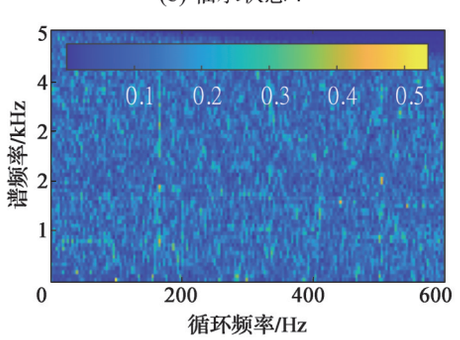

(c) 轴承状态 5

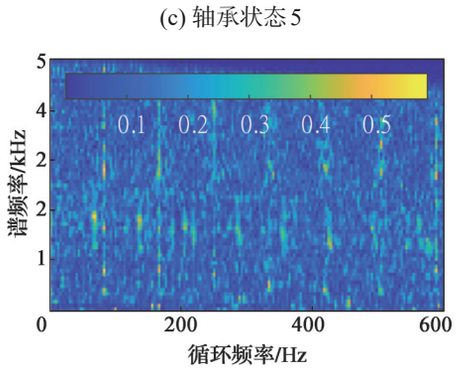

(d) 轴承状态 6

图 10　基于 Fast-SC 的循环相干图

Fig. 10　Cyclic coherence diagrams based on Fast-SC

综上所述，CMQGWT 方法擅长表征低频成分，但这难以避免引入低频干扰成分，而 Fast-SC 方法则关注轴承缺陷激发的高频共振带与循环特征频率，但它容易受到噪声干扰，因此本文结合这 2 种时频分析方法，实现从低频到高频全覆盖的故障振动信号分析。本文将这 2 类时频分析图作为 CNN 的输入，提出了一种基于双通道特征融合的轴承故障诊断方法，利用 CNN 的“卷积+池化”操作逐步弱化干扰成分的影响，从而聚焦故障特征，增强淹没在干扰成分的故障特征信息表征，实现海量数据集下的故障分类与预测。

4.3　试验结果分析

选取其中 1 组数据集进行试验，并且将双输入通道 CNN 模型与单输入通道的 CNN 模型，以及 WDCNN 模型[19]、Alexnet 模型[20]和深度卷积生成对抗网络模型[21]（Deep Convolution Generative Adversarial Networks，DCGAN）进行性能对比。

根据相关研究和专家经验[9]，设置模型训练时的最大迭代次数为 120 次，初始学习率为 0.001，并采用 SGDM（Stochastic Gradient Descent with Momentum）算法作为参数优化方法。图 11 为双输入通道模型在训练过程中的损失函数与准确率变化曲线。由图 11 可知，随着迭代次数的增加，模型训练过程的损失值整体呈现下降的趋势，迭代至后期，曲线斜率的绝对值已经趋于 0；与此同时，模型训练过程的准确率也随着迭代的进行而上升，迭代至 50 次左右收敛，模型的准确率稳定保持在 100% 左右。

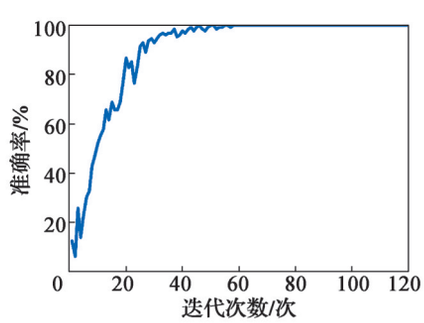

(a) 准确率变化曲线

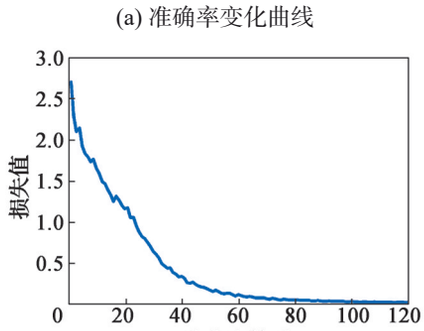

(b) 损失函数变化曲线

图 11　双输入通道模型训练进度

Fig. 11　Training progress of model with dual input channels

利用混淆矩阵展示双输入通道模型对于滚动轴承单个故障和复合故障状态的区分能力，如图 12 所示，标签类别 1 ~ 7 分别与表 2 中的轴承状态类别相对应。双输入通道模型的最终诊断准确率为 100%，实现了对所有滚动轴承状态的正确诊断。

单输入 CMQGWT 时频图的 CNN 模型诊断结果如图 13(a)所示，模型对所有样本的诊断准确率为 93.6%，

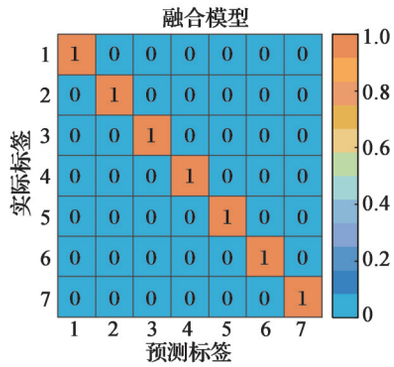

图 12　双输入通道模型预测结果

Fig. 12　Prediction results of model with dual input channels

但对于轴承状态“3”“7”的滚动轴承存在误诊情况，部分属于轴承状态“3”的样本状态被误诊为轴承状态“2”和轴承状态“5”，该类故障诊断准确率仅为 79%；单输入 Fast-SC 时频图的 CNN 模型诊断结果如图 13(b)所示，模型对所有样本的诊断准确率为 95.0%，模型对于轴承状态“7”的诊断效果明显不佳，该类故障诊断准确率仅为 76%。因此，相比于 2 个单输入通道 CNN 模型，双输入通道模型的诊断准确率更高，对于各类滚动轴承状态均能实现较好的区分，诊断能力更加强大。此外，2 种单输入通道的深度模型在训练过程中的准确率和损失函数曲线分别如图 14 和图 15 所示。由 14 和图 15 可知，2 个单输入通道模型均迭代至 120 次左右才呈现出大致收敛的趋势。因此，双输入通道模型不仅在准确率上高于 2 个单输入通道的 CNN 模型，而且

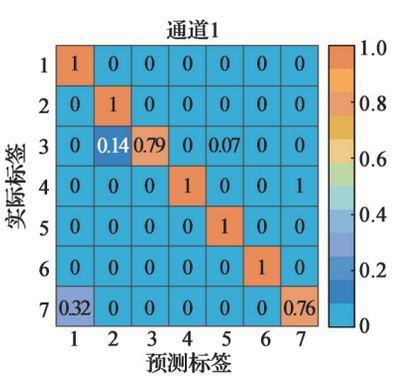

(a) 单输入通道 1

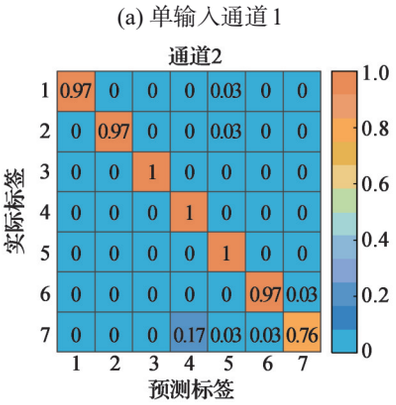

(b) 单输入通道 2

图 13　单输入通道模型预测结果

Fig. 13　Prediction results of model with single input channel

收敛速度也更快。

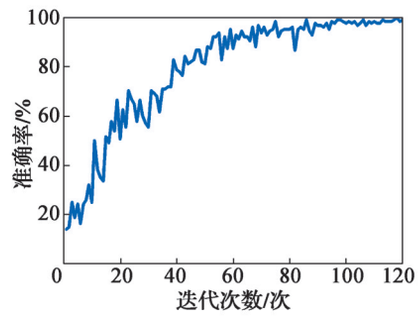

(a) 单输入通道 1

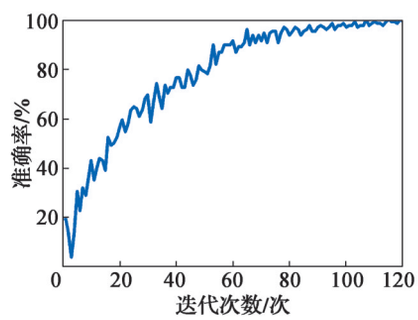

(b) 单输入通道 2

图 14　单输入通道模型的准确率变化曲线

Fig. 14　Accuracy variation curve of model with single input channel

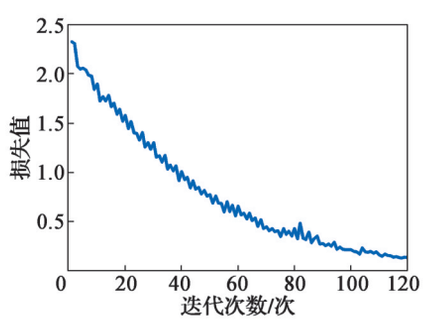

(a) 单输入通道 1

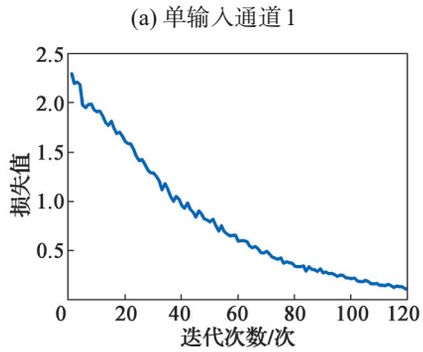

(b) 单输入通道 2

图 15　单输入通道模型的损失函数变化曲线

Fig. 15　Loss function variation curve of model with single input channel

为了更加有效地凸显双通道特征融合模型与单通道模型在故障分类能力上的差异，采用 t-SNE 的可视化技术对单通道模型和双通道融合模型的特征输出层进行可视化处理，分别得到如图 16 和图 17 所示的可视化

结果。由图 16 可知，单通道模型特征输出层的轴承状态存在部分重叠、边界模糊等现象，其中通道 1 特征输出层的状态类别“1”和“2”区分良好，而通道 2 的特征输出层未能将 2 种轴承状态有效区分；通道 1 特征输出层的状态类别“3”和“5”区分性较差，而通道 2 的特征输出层显示状态类别“3”和“5”区分良好。双通道融合模型的可视化结果如图 17 所示。由图 17 可知，各滚动轴承状态特征均高度聚集，不同轴承状态间具有一定的间隔，区分度良好。由此可见，双通道特征融合模型综合了单通道模型的特征提取能力，具有更优异的故障分类能力。

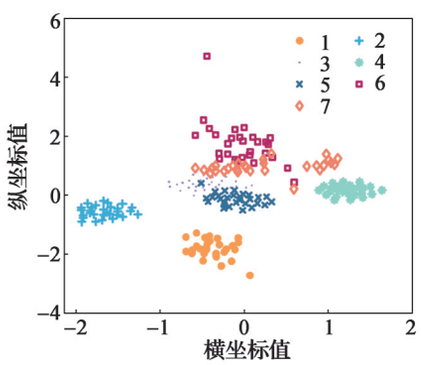

(a) 通道 1 的特征输出层

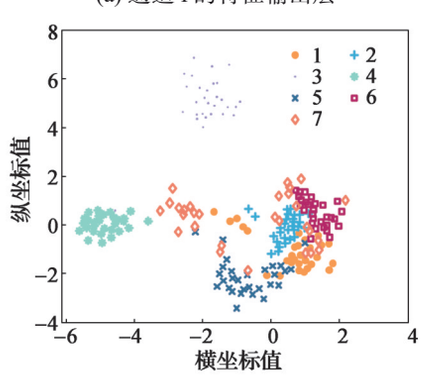

(b) 通道 2 的特征输出层

图 16　单通道模型的可视化结果

Fig. 16　Visual presentation of results from single-channel model

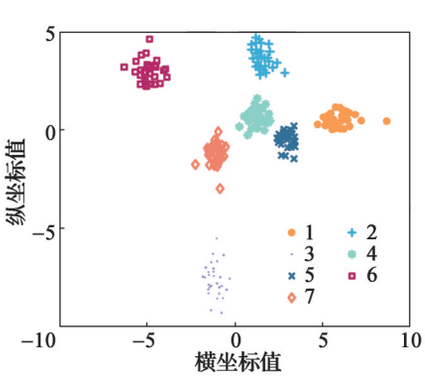

图 17　双通道融合模型的可视化结果

Fig. 17　Visual presentation of results from dule-channel fusion model

为了避免结果的偶然性，重复以上步骤，完成剩余 4 组数据集的训练和测试，测试集的准确率如图 18 所示。由图 18 可知，双输入通道模型对于滚动轴承单个故障和混合故障的诊断能力稳定性较好，诊断准确率值的大小波动较小，鲁棒性明显好于单通道模型；经过计算，单输入 CMQGWT 时频图的 CNN 模型平均准确率为 93.4%，单输入 Fast-SC 的 CNN 模型平均准确率为 91.2%，双输入通道 CNN 模型的平均准确率为 99.4%。总体而言，双输入通道 CNN 模型由于提取并综合了 2 类输入源的特征信息，因此具有更强的故障诊断能力，泛化能力更强，所输出的诊断结果也具有更高的精度和可靠性。

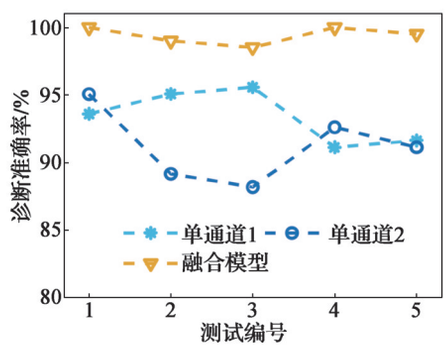

图 18　5 次测试的诊断准确率对比

Fig. 18　Comparison of diagnostic accuracy among 5 experiments

此外，将数据样本分别导入 WDCNN 模型、AlexNet 模型和 DCGAN 模型进行训练和测试。仍然基于 5 组数据集，得到测试结果如表 4 所示。由表 4 数据可知，本文所研究的双输入通道模型的诊断性能不仅优于单通道 CNN 模型，而且优于 WDCNN 模型、AlexNet 模型和 DCGAN 模型。

表 4　平均准确率对比

Table 4　Comparison of average accuracy

模型	平均准确率/%
WDCNN	93.4
AlexNet	98.5
DCGAN	92.3
双输入通道的 CNN	99.4

综上所述，双输入通道模型能够利用内部隐藏层实现对 2 个输入源的深层特征自动提取，并将 2 个输入源的特征融合成为 1 个深度时频特征，实现对单一通道提取特征的“优势互补”。双输入通道模型对轴承故障的平均诊断率达 99.4%，高于单一输入源的 CNN 模型，而且稳定性更好、鲁棒性更优；该模型的诊断性能亦优于 WDCNN 模型、AlexNet 模型和 DCGAN 模型等常见深度学习模型。

5　结论

为了提高传统 CNN 模型诊断准确性和鲁棒性，将 CMQGWT 和 Fast-SC 理论应用于 CNN 模型的构建，本

文提出了一种双通道特征融合的轴承故障诊断方法，搭建了具有双输入通道的CNN模型，主要结论如下：

①本文所提模型具有2个输入源，能够将2个不同来源的深度特征融合为1个包含多尺度细节的深度特征，使得融合后的数据特征更贴近于表征原始数据样本的真实情况。

②试验结果表明，本文所提模型的平均诊断率高于单一输入源的CNN模型，而且稳定性更好、鲁棒性更优、收敛速度更快。此外，该模型的平均诊断率也高于WDCNN模型、Alexnet模型和DCGAN模型等常见深度学习模型，亦证明了该模型的有效性与优越性。

参考文献：

[1] WU Wenyi, YI Cai, BAI Jie, et al. Envelope harmonic noise ratio based adaptive kurtogram and its application in bearing compound fault identification[J]. IEEE sensors journal, 2022, 22(9): 8701-8714.

[2] 张西宁, 郭清林, 刘书语. 深度学习技术及其故障诊断应用分析与展望[J]. 西安交通大学学报, 2020, 54(12): 1-13.
ZHANG Xining, GUO Qinglin, LIU Shuyu. Analysis and prospect of deep learning technology and its fault diagnosis application[J]. Journal of Xi'an jiaotong university, 2020, 54 (12): 1-13.

[3] 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 Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of mechanical engineering, 2018, 54 (5): 94-104.

[4] 林诗麒, 陈智丽, 李宇鹏, 等. 基于深度学习和多域决策融合的轴承故障智能诊断技术[J/OL]. 计算机集成制造系统 : 1-15. (2022-08-17) [2023-10-22]. http://kns. cnki. net/kcms/detail/11.5946.TP.20220816.1522.004.html.
LIN Shiqi, CHEN Zhili, LI Yupeng, et al. Intelligent bearing fault diagnosis technology based on deep learning and multi-domain decision fusion[J/OL]. Computer integrated manufacturing systems: 1-15. (2022-08-17) [2023-10-22]. http://kns. cnki. net/kcms/detail/11.5946. TP. 20220816.1522.004.html.

[5] 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.

[6] 唐波, 陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.
TANG Bo, CHEN Shenshen. Method of bearing fault diagnosis based on deep convolutional neural network[J]. Journal of electronic measurement and instrument, 2020, 34(3): 88-93.

[7] 杨劼立, 林建辉, 谌亮. 基于MED辅助特征提取CNN模型的列车轴承故障诊断方法[J]. 中国测试, 2020, 46(10): 124-129.
YANG Jieli, LIN Jianhui, CHEN Liang. Fault diagnosis method for train bearings based on MED-assisted feature extraction CNN model[J]. China measurement & test, 2020, 46 (10): 124-129.

[8] DING Xiaoxi, HE Qingbo. Energy-fluctuated multiscale feature learning with deep ConvNet for intelligent spindle bearing fault diagnosis[J]. IEEE transactions on instrumentation and measurement, 2017, 66(8): 1926-1935.

[9] SITTLER R W. An optimal data association problem in surveillance theory[J]. IEEE transactions on military electronics, 1964, 8(2): 125-139.

[10] TANG Xianghong, GU Xin, WANG Jiachen, et al. A bearing fault diagnosis method based on feature selection feedback network and improved D-S evidence fusion[J]. IEEE access, 2020, 8: 20523-20536.

[11] HOANG D T, KANG H J. A motor current signal-based bearing fault diagnosis using deep learning and information fusion[J]. IEEE transactions on instrumentation and measurement, 2020, 69(6): 3325-3333.

[12] 齐咏生, 白宇, 高胜利, 等. 基于改进的数据融合滚动轴承故障诊断[J]. 铁道学报, 2022, 44(10): 24-32.
QI Yongsheng, BAI Yu, GAO Shengli, et al. Fault diagnosis of rolling bearing based on improved data fusion[J]. Journal of the China railway society, 2022, 44(10): 24-32.

[13] ZHANG Xin, LIU Zhiwen, WANG Jiaxu, et al. Time-frequency analysis for bearing fault diagnosis using multiple Q-factor Gabor wavelets[J]. ISA transactions, 2019, 87: 225-234.

[14] 唐贵基, 田甜, 庞彬. 基于总变差去噪和快速谱相关的滚动轴承故障诊断[J]. 振动与冲击, 2019, 38(11): 187-193.
TANG Guiji, TIAN Tian, PANG Bin. Rolling bearing fault diagnosis method based on total variation de-noising and fast spectral correlation[J]. Journal of vibration and shock, 2019, 38(11): 187-193.

[15] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural computation, 1989, 1(4): 541-551.

[16] 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.

[17] 樊星男, 刘晓娟. 二维卷积神经网络在轴承故障诊断中的应用[J]. 机械设计与研究, 2022, 38(3): 109-113.
FAN Xingnan, LIU Xiaojuan. Application of two-dimensional convolution neural network in bearing fault diagnosis[J]. Machine design & research, 2022, 38(3): 109-113.

[18] 李大柱, 牛江, 梁树林, 等. 基于多尺度时频图与卷积神经网络的车轮故障智能诊断[J]. 铁道科学与工程学报, 2023, 20(3): 1032-1043.
LI Dazhu, NIU Jiang, LIANG Shulin, et al. Intelligent wheel fault diagnosis based on multi-scale time-frequency map and convolutional neural network[J]. Journal of railway science and engineering, 2023, 20(3): 1032-1043.

[19] GAO Yangde, KIM C H, KIM J M. A novel hybrid deep learning method for fault diagnosis of rotating machinery based on extended WDCNN and long short-term memory [J]. Sensors, 2021, 21(19): 6614.

[20] SHI Xiaoyu, QIU Gen, YIN Chun, et al. An improved bearing fault diagnosis scheme based on hierarchical fuzzy entropy and alexnet network[J]. IEEE access, 2021, 9: 61710-61720.

[21] HE You, TANG Hesheng, REN Yan, et al. A semi-supervised fault diagnosis method for axial piston pump bearings based on DCGAN[J]. Measurement science and technology, 2021, 32(12): 125104.

收稿日期：2023-08-17
修回日期：2023-10-25