Fault Diagnosis of Fan Bearings Based on Time-Frequency Spectrum Features and Deep Convolutional Neural Networks*

XU Guangqian[1], JIN Wei[1], WU Xuanchen[1], HE Xinrong[2], ZHOU Zhongzhi[3,4*], DENG Aidong[3,4]
(1.Guoneng Changzhou Power Generation Co., Ltd., Changzhou Jiangsu 213033; 2.China Energy Science and Technology Research Institute Co., Ltd., Nanjing Jiangsu 210023, China; 3.National Engineering Research Center of Power Generation Control and Safety, Nanjing Jiangsu 210096, China; 4.School of Energy and Environment, Southeast University, Nanjing Jiangsu 210096, China)

Abstract: To address the difficulty in effectively extracting time-varying vibration characteristics of fan bearings during real-time operation, an improved time-frequency spectrum is employed to enhance signal representation, and the powerful discriminative capability of deep convolutional neural network is leveraged to achieve accurate diagnosis of non-stationary bearing vibration frequency features. First, preprocessing methods including frame splitting, windowing, and time-domain averaging are applied to improve the characterization of component states in the joint time-frequency distribution. Second, by utilizing the local connectivity and weight-sharing mechanism of the deep convolutional neural network, discriminative features in the vibration signals are automatically learned, enabling effective differentiation of various bearing health conditions. Theoretical analysis and experimental results demonstrate that the time-frequency features derived by this method exhibit distinct identifiability for bearing faults, showing satisfactory fault recognition performance and noise robustness.

Key words: bearing; fault diagnosis; time-frequency spectrum feature; deep convolutional neural network
EEACC: 7220 **doi**: 10.3969/j.issn.1005-9490.2026.04.020

基于时频谱特征与深度卷积神经网络的风机轴承故障诊断*

徐光前[1], 金 伟[1], 吴炫辰[1], 何新荣[2], 周忠志[3,4*], 邓艾东[3,4]
(1.国能常州发电有限公司, 江苏 常州 213033; 2.国家能源集团科学技术研究院有限公司, 江苏 南京 210023; 3.大型发电装备安全运行与智能测控国家工程研究中心, 江苏 南京 210096; 4.东南大学能源与环境学院, 江苏 南京 210096)

摘 要: 针对风机轴承在实时运行中振动的时变特征难以得到有效挖掘的问题, 为充分描述轴承的非平稳信号频率的时序特征, 利用改进的时频谱提升信号表征, 并借助深度卷积神经网络的强大辨识能力, 实现对非平稳轴承振动频率特征的精准诊断。首先, 采用分帧加窗和时域平均的预处理方法, 增强了信号在时频联合分布的维度上对部件状态的特征表达; 其次, 利用深度卷积神经网络的局部连接和权重共享机制, 自动学习振动信号中的判别性特征, 从而有效区分轴承的不同健康状态。理论分析和实验结果表明, 该方法的时频特征对轴承故障具有明显的辨识度, 具有较好的故障识别性能和抗噪鲁棒性。

关键词: 轴承; 故障诊断; 时频谱特征; 深度卷积神经网络
中图分类号: TH133.3 **文献标识码**: A **文章编号**: 1005-9490(2026)04-0743-07

风机作为火电厂中广泛应用的旋转机械设备, 其核心部件滚动轴承发挥着类似“运动枢纽”的关键作用。然而, 在实际运行过程中, 滚动轴承长期承受着周期性应力、机械磨损以及环境腐蚀等多重因素的影响, 这使得它成为风机系统中最容易出现故障的薄弱环节之一[1]。深入研究滚动轴承故障的快速诊断技术, 及时识别并排除设备潜在风险, 对提升风机系统的运行稳定性和经济效益具有重要的实践价值。在旋转机械的故障诊断研究中, 振动分析方法居于核心地位, 并已发展出一系列成熟的应用方案[2]。通过分析振动信号, 提取有效的时域、频域及时频域特征以构建设备状态诊断模型, 实现对设备运行的健康状态判别[3], 其中的关键环节在于有效特征和诊断模型的构建。

目前可用于表征设备运行状态的振动特征多种多样, 主要集中在时域、频域以及时频域三种不同角度对信号进行特征分析[4-6]。在时域分析中可以通过计算信号的均值、均方根值、峭度、峰值、脉冲因子、裕度系数等统计指标随时间的变化情况来反映信号的时序特征[7]。为了捕捉滚动轴承振动的演

项目来源: 国家自然科学基金面上项目(52576010); 国家能源集团科技创新项目(GJNY-23-68)
收稿日期: 2026-05-25 **修改日期**: 2026-06-15

变趋势,黎红志等[8]、孟德乾等[9]重点分析了振动信号的时序特征。该方法计算简单方便,但只能用于大致描述设备在生命周期中的健康状态,无法描述故障类型,以致诊断结果不够完备。频域分析方法(如快速傅里叶变换,FFT)将信号映射至频域,通过特征频率的识别来实现故障类型的诊断与诊断结果的优化。孙鹏[10]、朱静等[11]将时域信号映射到频域,并对故障特征频率进行包络谱分析,实现对滚动轴承不同故障类型的精确诊断。然而,对于时变的非平稳信号,频域分析提供的是一种“全局平均”的频谱视图,无法获取频率在时间轴上的局部化特征。如何将时域和频域特征两座数据孤岛有效联系起来,结合设备实时工作运行数据的时变性,构建能够全面且精准表征设备运行状态的特征,是领域内的一项关键研究内容。

时频分析为理解非平稳信号提供了时频联合的视角,能够有效揭示其频率成分的时变机制,这使其成为该领域的研究热点[12]。在信号处理领域,主流的时频分析技术主要包含三大类别:线性时频分析法、自适应时频分析法和非线性时频分析法三大类[13]。线性分析依赖于预设的固定窗函数,通过短时傅里叶变换实现局部平稳近似。自适应分析得益于信号驱动的分解机制,能自适应地分离出本征模态分量以刻画瞬时频率。而非线性分析则不依赖于线性或平稳假设,通过非线性变换获得能量更为集中的时频表示。通常根据信号分布情况采用不同的核函数,特别当核函数为 1 时,等同于时间和频率的线性时频分析[14]。然而,由于其固有算法机制的局限性,该方法在处理多分量信号时难以完全抑制交叉项的出现。针对轴承设备振动信号特点,本文提出了一种改进非线性时频分析算法,在时间和频率维度上分别加窗和平均,削弱交叉耦合项的干扰,增强设备状态的时频图像特征,为后续风机滚动轴承故障分析判别提供依据。

通过构建时频特征图像,故障识别就转变为图像的识别问题。深度卷积神经网络通过卷积层过滤器的作用,可以自动学习时频图像的全局和局部特征。网络凭借其独特的结构特性,包括局部感受野机制、参数共享策略以及时空下采样设计,不仅能够有效提取输入数据的局部关联特征,同时精简网络参数量。这种架构设计同时赋予了模型对目标位置偏移和形态变化的鲁棒性[15-16]。因此,本文提出了基于改进时频谱特征和深度卷积神经网络的风机轴承故障识别算法,利用信号处理与神经网络的结合实现轴承故障类型的精确识别。

1 基于时频特征深度学习的风机诊断模型

本文提出的风机轴承智能诊断模型整体流程如图 1 所示。首先,对通过加速度传感器获得的轴承振动信号进行分帧,逐段提取其时频特征;进而,对这些特征进行时域同步平均以增强代表性;最终,将经过处理后的平均时频谱输入 CNN 模型中进行训练,进而实现滚动轴承的故障诊断识别。

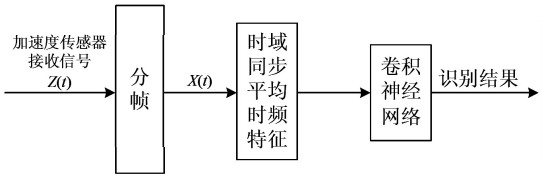

图 1 风机故障识别流程图

1.1 改进时频谱特征提取算法

时频分析是将一维时序信号以二维的时间-频率联合分布表示出来,不仅得到信号的各种频率成分,还能建立各频率成分在时间维度上的对应关系。其中,维格纳-威利分布(Wigner-Ville Distribution,WVD)被广泛认为具有计算简单、时频聚集性好和表示直观的特点,这些特性使其在理论研究和工程应用中备受关注[17]。作为一种双线性时频分析工具,它通过计算瞬时自相关函数的傅里叶积分来实现对信号时频特征的联合分析。为改善 WVD 在分析多分量信号时的性能,后续研究随之产生了多种改进方案,例如伪维格纳-威利分布(Pseudo Wigner Ville Distribution,PWVD),其显著优势在于能够有效克服由自相关函数引起的交叉项干扰。PWVD 在保留 WVD 高时频聚焦性的同时,显著抑制了交叉项,展现出更优的时频分析性能[18]。因此,在 PWVD 的时频分析基础上,提出了改进的时频谱特征提取算法。

对于信号 $s(t)$,其 WVD 被定义为:

$$W_s(t,\Omega)=\int_{-\infty}^{\infty}x(t+\tau/2)x^*(t-\tau/2)e^{-j\Omega\tau}d\tau \quad (1)$$

式中:$x(t)$为 Hilbert 变换得到的解析信号,$x^*(t)$为 $x(t)$的复共轭。得到的解析信号带宽减半,避免了信号中负频率的畸变影响,同时可有效降低交叉项干扰。$x(t+\tau/2)x^*(t-\tau/2)$是信号 $x(t)$的瞬时自相关函数,因此 $W_s(t,\Omega)$为信号 $x(t)$的局部功率谱。

为更有效地抑制交叉干扰项,研究在时间维度上采取了加窗策略,即应用 Hamming 窗,其机理在于该窗函数能显著降低信号的旁瓣强度。改进后的 WVD 分布可表达为:

$$PW_s(t,\Omega)=\int_{-\Delta/2}^{\Delta/2}h(\tau/2)x(t+\tau/2)x^*(t-\tau/2)e^{-j\Omega\tau}d\tau \quad (2)$$

对式(2)离散化,令 $t=nT_s$,其中 T_s 为采样间隔时间。将信号按长度为 $D=2M-1$ 的 Hamming 窗等长分为 P 段,各段分别求改进的 WVD 分布,再相加求平均值,得到时域平均后的时频谱特征。可得:

$$\mathrm{PW}_s(nT_s,\Omega)=2T_s\sum_{m=-M+1}^{m=M-1}h(mT_s)x(nT_s+mT_s)x^*(nT_s-mT_s)\mathrm{e}^{-\mathrm{j}2\,m\Omega T_s} \tag{3}$$

归一化,令 $T_s=1$,$\omega=\Omega T_s$,可得:

$$\mathrm{PW}_s(n,\omega)=2\sum_{m=-M+1}^{m=M-1}h(m)x(n+m)x^*(n-m)\mathrm{e}^{-\mathrm{j}2m\omega} \tag{4}$$

1.2　基于 CNN 的轴承故障诊断模型

作为深度学习的代表性模型,卷积神经网络(Convolutional Neural Network,CNN)有着强大的特征学习能力,其应用已从图像、语音、文本分析成功拓展至工业故障诊断等多个前沿领域。在 CNN 应用于故障诊断的探索中,梁敏健等[19]通过在自动扶梯诊断中构建复合数据集与数据增强,达到了 95% 的分类精度。在此基础上,刘洋等[20]为进一步提升模型在真实工业场景(如噪声、变工况)下的适应性,基于 1D-CNN 引入了注意力模块,显著增强了滚动轴承在复杂环境下故障诊断的鲁棒性。

本研究构建的 CNN 结构如图 2 所示。该网络以时频特征作为输入,依次经过三个卷积-池化模块进行处理:首个卷积层使用 64 个 3×3 滤波器;第二个卷积层配置 16 个 2×2 卷积核;第三个卷积层采用 8 个 4×4 卷积核。每个卷积层后均接入一个 2×2 最大值池化层进行下采样。经特征提取后,数据被展平并送入全连接层,最终由分类器输出诊断结果。在模型训练中,设置最小批处理量为 64,迭代 200 个周期,初始学习率为 0.000 2,并采用 Adam 算法最小化交叉熵损失以优化网络参数。

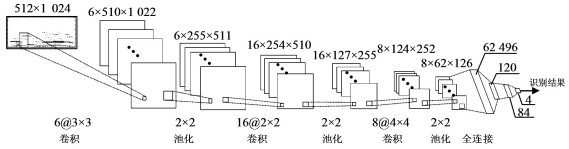

图 2　CNN 网络结构

CNN 的训练流程主要涵盖参数初始化、前向计算与误差反向传播三个核心环节。初始阶段需对网络各层的权重和偏置进行初始化赋值,其目的在于为后续的优化过程设定初始起点。随后进入正向计算过程,将批量输入数据依次通过多个卷积-池化操作模块,最终由分类器输出预测结果。在反向传播阶段,采用反向传播(Back Propagation,BP)算法计算损失函数对各层参数的梯度,通过链式求导法则实现误差信号的逐层回传,并利用优化算法对网络参数进行迭代更新,直至预定的收敛标准。

2　实验结果分析

2.1　改进时频特征的有效性分析

实验数据取自凯斯西储大学(CWRU)公开的滚动轴承数据集,用以验证所提方法的有效性。实验涵盖了正常、外圈失效、内圈失效及滚动体失效共四种健康状况。其中,故障状态涉及三种单一故障点直径(0.007 inch、0.014 inch 和 0.02 inch)。数据采集自 SKF 轴承,其在 1 797 rad/min 的恒定转速下运行,并使用采样频率为 12 kHz 的加速度传感器获取振动信号,每种工况下各获得 350 个样本。图 3 展示了各类工况下的典型振动信号波形。

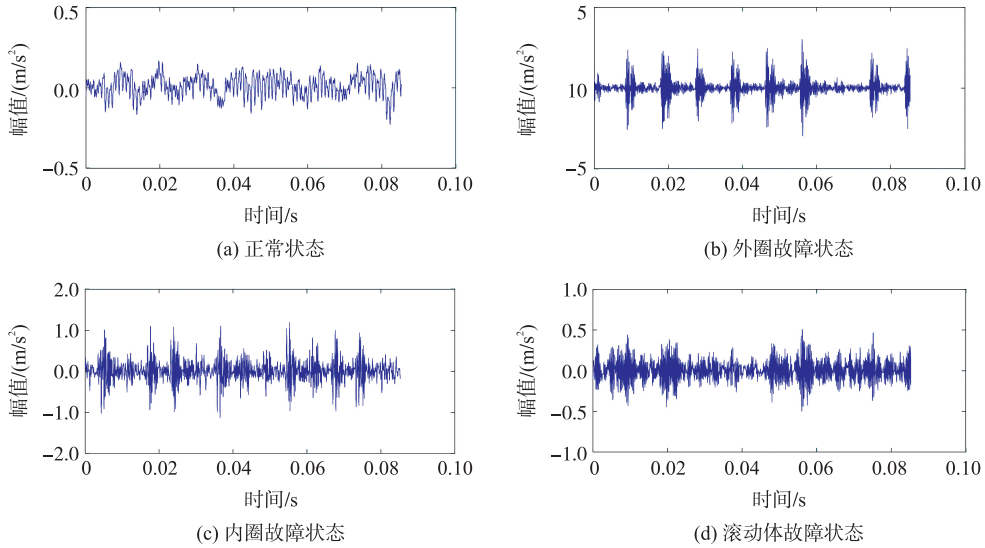

图 3　轴承振动信号的波形图

从图 3 可以发现,外圈故障有着较其他状态更大的振动幅值;除正常状态外,轴承在不同故障状态下均体现出明显的信号冲击,尤以外圈和内圈故障的冲击尤为突出,且表现出一定的周期性。为此,本研究提取了所有样本的时频特征,最终得到图 4 和图 5 所示的时频图像特征集。

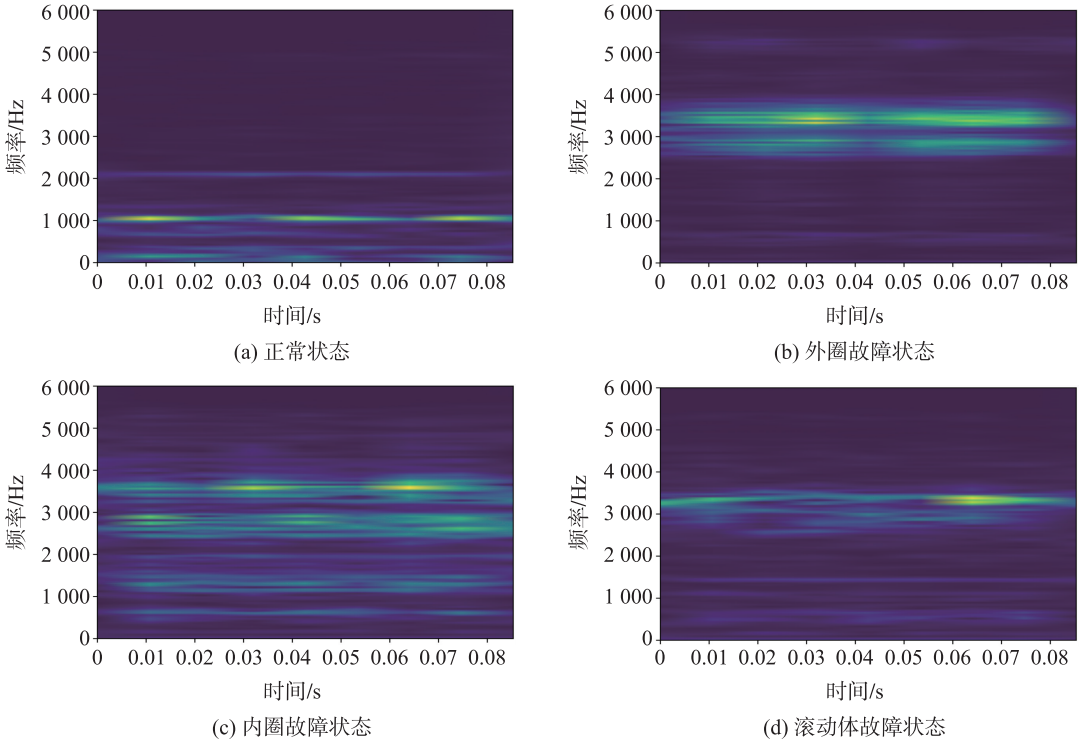

图 4 滚动轴承的时频谱特征图

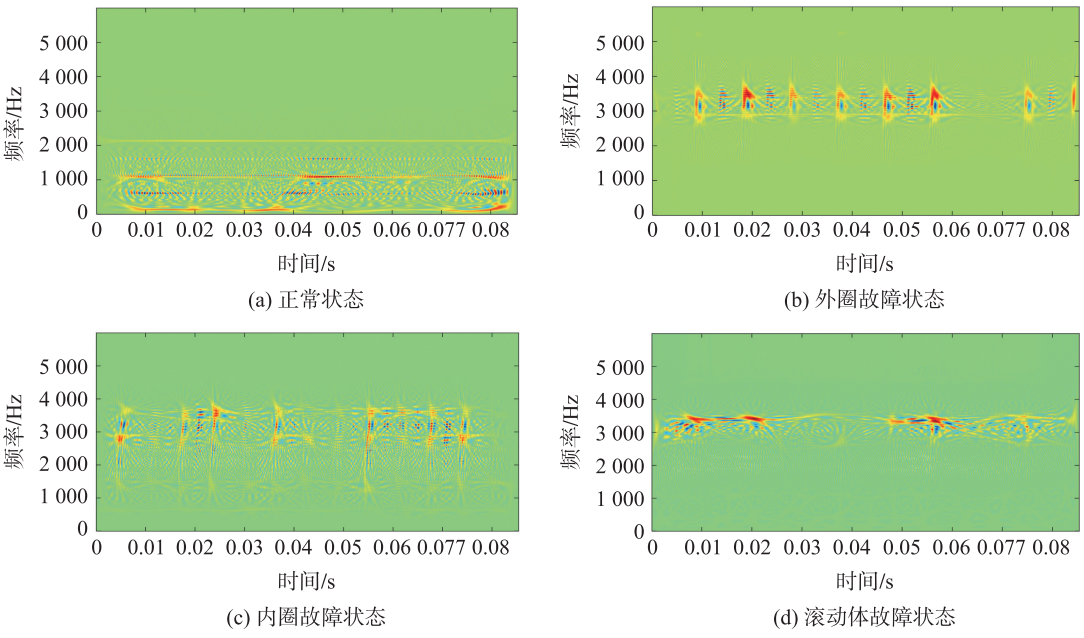

图 5 滚动轴承的改进时频谱特征

如图 5 所示,时频特征图像的尺寸为 512×1 024。可以观察到,轴承在正常状态下,能量主要分布在 0~1 000 Hz 频带内,当发生故障后,其能量则集中在 3 000 Hz 附近。基于仿真信号的验证分析表明,相较于短时傅里叶变换,本文方法获得的时频谱在频率分辨率上具有明显优势,在故障特征的表达方面表现较为突出。特征清晰度是决定模型识别率上限的核心因素,因此,采用本方法所提的高精度时频特征,可为滚动轴承故障诊断模型的构建提供更坚实的依据。

2.2　理想状态下算法的识别结果分析

本文采用 1.2 节所构建的 CNN 网络进行训练，其中，训练集与测试集的划分比例为 4∶1；批量大小（Batch Size）为 70。图 6 展示了训练损失的变化曲线，可见模型在第 50 次迭代后损失不再显著下降，表明其已基本达到收敛状态。

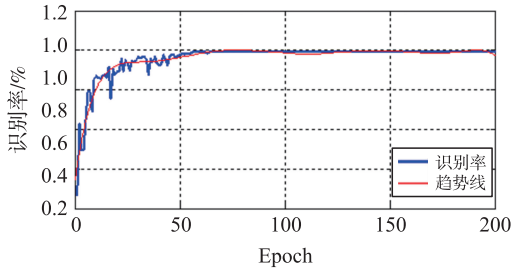

(a) 不同Epoch下的识别结果

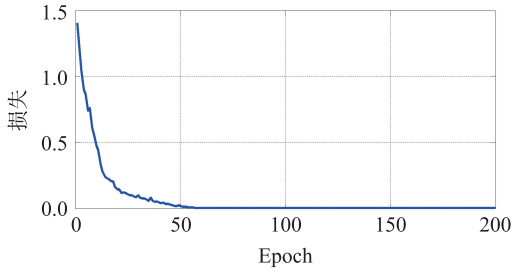

(b) 不同Epoch下的损失结果

图 6　CNN 模型在训练过程中的误差收敛曲线

为避免实验误差，保证测试结果的稳定性，本节及后续实验得到的结果均取 10 次重复实验的平均值。如图 7 所示，所提方法对轴承的四种健康状态（正常、内圈故障、外圈故障、滚动体故障）的诊断识别率分别为 98.51%、100%、98.61%和 100%，其识别率和稳定性较为显著。

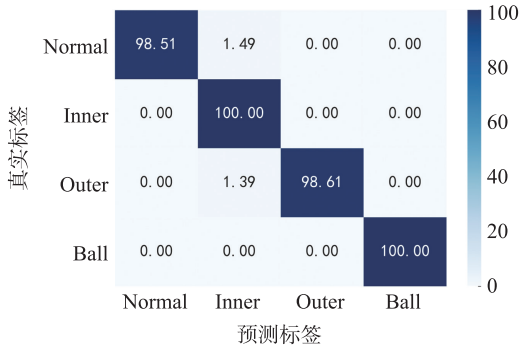

图 7　滚动轴承故障识别结果

本文提出的方法深度融合了改进的时频谱与深度卷积神经网络，能够自适应地从时频图像中提取判别性特征，避免了人工特征提取的主观性与局限性，展现出卓越的端到端识别能力。实验结果表明，在故障识别精度与抗噪鲁棒性方面，该方法均有着出色的表现。

2.3　噪声影响下算法的识别效果

为了验证所提方法在噪声环境下的诊断性能，本节设计了对比实验：在原始振动信号中添加−5 dB 高斯白噪声以模拟强噪声工业环境，并以基于短时傅里叶时频谱的诊断方法作为对比基准。如图 8 所示，在此噪声环境下，本文方法的训练损失在 100 次迭代后即趋于稳定并接近零，验证了所提方法在噪声背景下的鲁棒性。

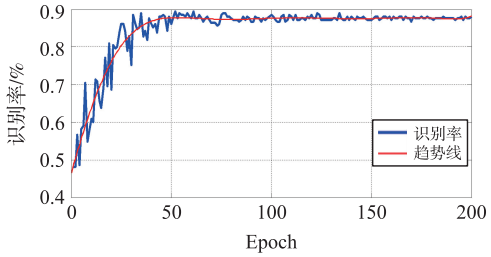

(a) 不同Epoch下的识别结果

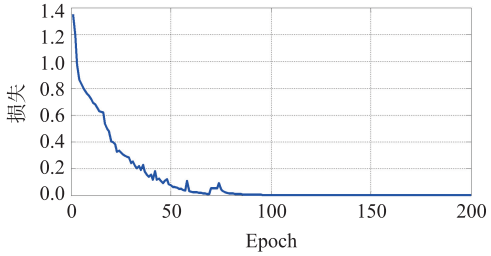

(b) 不同Epoch下的损失结果

图 8　所提方法的训练误差收敛曲线（信噪比：−5 dB）

从图 9 中可以看出，相比于未加入高斯白噪声的原始振动信号，所提方法在滚动体故障的识别上保持 100%的准确率，对正常、内圈和外圈故障的识别率分别为 86.76%、72%和 94.52%。经过分析可以发现，轴承样本中 22.67%的内圈故障被识别为正常，而 10.3%的正常样本被识别为内圈故障。这表明在强噪声背景下，轴承内圈故障的敏感特征易被噪声淹没，使其与正常状态下的表征产生混淆，进而增加诊断难度。与基于短时傅里叶时频谱的对比方法（图 10）相比，本文方法在四种状态上的识别率分别高出 4.51%、5.03%、3.28%和 2.47%。实验结果

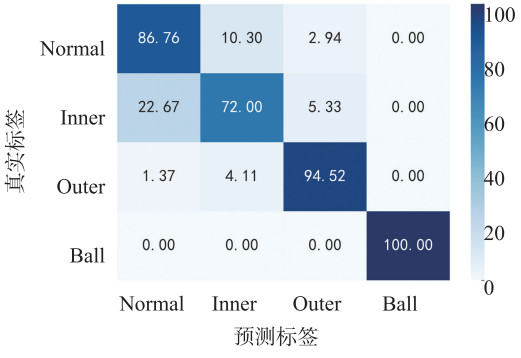

图 9　所提方法的故障识别结果（信噪比：−5 dB）

证明,本文方法能提取更具判别力的特征,从而显著提升诊断模型在噪声环境下的鲁棒性。

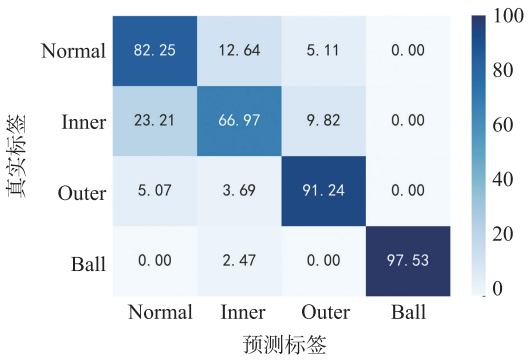

图 10 对比方法的识别结果(信噪比:-5 dB)

2.4 基于传统特征的基准方法性能对比分析

本研究选取支持向量机(Support Vector Machine,SVM)与误差反向传播(BP)神经网络作为对比基准,以验证所提方法的优越性。其中,SVM 与 BP 模型采用相同的输入特征,且所有指标均经过归一化预处理。在具体参数方面:SVM 采用网格搜索法确定最优参数组合;BP 网络则设计为包含 10 个隐层神经元的单隐层结构,其训练误差目标、最大迭代次数分别设置为 0.000 1 和 10 000,网络初始权值进行随机初始化。

表 1 中的数据展示了不同方法的诊断结果。与本文所提的方法相比,SVM 模型对轴承的多种健康状态(滚动体故障、内圈故障、正常和外圈故障)的识别率分别下降了 8.85%、7.83%、9.35% 和 11.19%;BP 神经网络模型则相应下降了 9.48%、10.79%、8.33%和 8.93%。结果表明,本文所提方法在轴承多种故障类型的识别中有着较其他模型更稳定且显著的优势。

表 1 多种模型识别率对比结果 单位:%

状态	DCNN	SVM	BP 神经网络
滚动体故障	100	91.15	90.52
内圈故障	100	92.17	89.21
正常	98.51	89.16	90.18
外圈故障	98.61	87.42	89.68

进一步分析可以发现,SVM 与 BP 模型依赖的是人为预先选择的 9 个时域特征,这种特征工程方法带有主观性,且难以全面捕捉故障的深层信息。相反,本文方法利用深度卷积神经网络强大的表征学习能力,能够直接从原始时频谱中自动进行全局性学习和局部特征抽取。这种端到端的特征学习机制避免人工干预,能自适应地挖掘出更具判别力的故障特征,可实现轴承的多种健康状态的准确识别。

3 结束语

为有效挖掘风机轴承在实时运行中的时变特征,实现轴承多种健康状态的准确识别,及时对故障部件进行隔离并更换,本文采用分帧加窗和平均的预处理方法改进表征设备状态的时频谱特征,构建轴承在多种健康状态下的时频谱特征集;并构建基于 DCNN 的故障诊断模型,增强二维谱特征对故障状态的表达,实现对滚动轴承故障的准确识别。该方法为实现设备的高效诊断提供了有效途径,将会大量减少资源的浪费和经济损失。

参考文献:

[1] 李昕燃,靳伍银. 基于改进麻雀算法优化支持向量机的滚动轴承故障诊断研究[J]. 振动与冲击,2023,42(6):106-114.

[2] 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.

[3] 邓向武,孙国玺,梁松,等. 基于同步提取变换的旋转机械振动信号时频分析[J]. 机床与液压,2022,50(7):181-186.

[4] 林水泉. 基于旋转机械滚动轴承的时域故障诊断方法[J]. 自动化技术与应用,2020,39(8):1-5,35.

[5] 焦卫东,丁祥满,严天宇,等. 基于频域特征波形模式匹配的故障诊断方法研究[J]. 华东交通大学学报,2021,38(2):73-81.

[6] 赵柄锡,冀大伟,袁奇,等. 采用时域与时频域联合特征空间的转子系统碰磨故障诊断[J]. 西安交通大学学报,2020,54(1):75-84.

[7] Deng A D,Cao H,Tong H,et al. Recognition of Acoustic Emission Signal Based on the Algorithms of TDNN and GMM[J]. Applied Mathematics & Information Sciences,2014,8(2):907-916.

[8] 黎红志,唐向红,陆见光,等. 端对端长短时序特征的轴承故障诊断[J]. 组合机床与自动化加工技术,2022(10):64-68.

[9] 孟德乾,徐军杨,袁建平,等. 基于深度特征提取与迁移学习的滚动轴承故障诊断[J]. 装备制造技术,2023(6):176-179,200.

[10] 孙鹏. 基于频谱分析和包络谱分析的滚动轴承故障诊断[C]//第 10 届全国转子动力学学术讨论会,昆明,2012:189-192.

[11] 朱静,邓艾东,钱丹阳,等. 基于振动和声发射技术的滚动轴承故障分析[J]. 自动化仪表,2018,39(1):53-57,61.

[12] Yang B Y,Liu R N,Chen X F. Sparse Time-Frequency Representation for Incipient Fault Diagnosis of Wind Turbine Drive Train[J]. IEEE Transactions on Instrumentation & Measurement,2018,67(11):2616-2627.

[13] Li H, He Q, Zhang Z. Overview of Time-Frequency Analysis Techniques in Vibration Signals of Rotating Machinery[J]. Applied Mechanics & Materials, 2014, 684: 124-130.

[14] Luo Z, Zeng L, Lin J. A Novel Time-Frequency Transform for Broadband Lamb Waves Dispersion Characteristics Analysis[J]. Structural Health Monitoring, 2021, 20(6): 3056-3074.

[15] 刘慧斌,李少波,张安思,等. 基于深度卷积神经网络的轴承多故障诊断研究[J]. 组合机床与自动化加工技术,2020(5):12-16.

[16] Wen L, Li X, Gao L, et al. A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Method[J]. IEEE Transactions on Industrial Electronics, 2018, 65(7):5990-5998.

[17] Kumar A, Prasad A. Wigner-Ville Distribution Function in the Framework of Linear Canonical Transform[J]. Journal of Pseudo-Differential Operators and Applications, 2022, 13(3):38.

[18] Sun K W, Yu B G, Elhajj M, et al. A Novel GNSS Interference Detection Method Based on Smoothed Pseudo-Wigner-Hough Transform[J]. Sensors, 2021, 21(13):4306.

[19] 梁敏健,彭晓军,刘德阳. 基于一维卷积神经网络的自动扶梯机械故障分类研究[J]. 测控技术,2022,41(7):87-92.

[20] 刘洋,程强,史曜炜,等. 基于注意力模块及 1D-CNN 的滚动轴承故障诊断[J]. 太阳能学报,2022,43(3):462-468.

徐光前(1969—),男,汉族,江苏镇江人,本科,工程师,研究方向为电厂设备管理、节能降碳研究及转动机械故障处理;

周忠志(1998—),男,汉族,山东聊城人,硕士研究生,研究方向为旋转机械智能故障诊断,230249543@seu.edu.cn。