

杨大炼,雷家乐,蒋玲莉.基于 MSB 和 CNN 的弧齿锥齿轮损伤故障识别[J].湖南科技大学学报(自然科学版),2023,38(4): 59-65. doi:10.13582/j.cnki.1672-9102.2023.04.008

YANG D L, LEI J L, JIANG L L. Recognition of Spiral Bevel Gear Damage Fault Based on Modulation Signal Bispectrum and Convolutional Neural Network[J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2023, 38(4): 59-65. doi:10.13582/j.cnki.1672-9102.2023.04.008

基于 MSB 和 CNN 的弧齿锥齿轮损伤故障识别

杨大炼^{1*}, 雷家乐¹, 蒋玲莉²

(1. 湖南科技大学 机械设备健康维护湖南省重点实验室, 湖南 湘潭 411201;

2. 佛山科学技术学院 机电工程与自动化学院, 广东 佛山 528225)

摘要:针对弧齿锥齿轮损伤程度识别率低的问题,提出一种基于调制信号双谱和卷积神经网络的弧齿锥齿轮损伤程度识别方法.采集弧齿锥齿轮在正常、轻度损伤及中度损伤 3 种状态下的振动加速度信号,分别计算其调制信号双谱特征图,构建卷积神经网络,并将调制信号双谱特征图作为输入样本训练卷积神经网络.试验结果表明:本文方法可以有效地提高弧齿锥齿轮损伤程度的识别率,平均识别准确率达 99.91%.

关键词:卷积神经网络;调制信号双谱;弧齿锥齿轮;故障诊断

中图分类号:TH132.1 文献标志码:A 文章编号:1672-9102(2023)04-0059-07

Recognition of Spiral Bevel Gear Damage Fault Based on Modulation Signal Bispectrum and Convolutional Neural Network

YANG Dalian¹, LEI Jiale¹, JIANG Lingli²

(1. Hunan Provincial Key Laboratory of Health Maintenance for Mechanical Equipment,
Hunan University of Science and Technology, Xiangtan 411201, China;

2. School of Mechatronic Engineering and Automation, Foshan University, Foshan 528225, China)

Abstract: Aiming at the problem of low recognition rate of spiral bevel gear damage fault degree, a spiral bevel gear damage degree recognition method based on modulation signal bispectrum and convolutional neural network is proposed. Firstly, the vibration acceleration signals of spiral bevel gear with normal, half broken and full broken teeth are collected. Then, the bispectrum feature maps of the modulation signals are calculated respectively. Finally, the convolutional neural network is constructed, and the bispectrum feature maps of the modulation signals are used as input samples to train the convolutional neural network. The experimental results show that the proposed method can effectively improve the recognition rate of spiral bevel gear damage path, and the average recognition accuracy is 99.91%.

Keywords: convolutional neural network; modulation signal bispectrum; spiral bevel gears; fault diagnosis

弧齿锥齿轮因工作平稳、传动比大、传递扭矩大、工作可靠和结构紧凑等优点被广泛应用于船舶动力

收稿日期:2021-04-14

基金项目:航空科学基金资助项目(20200033116001);湖南省自然科学基金资助项目(2021JJ30267);湖南省教育厅优秀青年项目资助(21B0484)

*通信作者, E-mail:hydl216@163.com

系统、直升机、航空发动机和汽车传动系统等装备.在长期重载、变载的运行工况下,一旦出现弧齿锥齿轮齿面损伤故障,轻则引起设备振动,降低传动性能,重则导致设备损坏甚至人员伤亡.因此,对弧齿锥齿轮的故障损伤程度进行准确识别,及时掌握损伤故障发展状态,为视情维护提供有效支持,对保障弧齿锥齿轮的安全稳定运行十分重要.

弧齿锥齿轮的啮合过程复杂多变,工作环境也较为复杂.由于故障振动信号具有强背景噪声、强非线性和非平稳等特性,导致其故障特征的识别比较困难^[1].调制信号双谱(Modulation Signal Bispectrum, MSB)具有强大的解调能力,不仅能有效处理非线性数据,还能抑制高斯噪声与非高斯噪声,且在强噪声环境下也能够获取旋转机械的故障特征.李加伟等^[2]提出一种基于频谱编辑和 MSB 的齿轮裂纹故障诊断方法,该方法能有效抑制谐波信号以及白噪声的干扰;郭俊超等^[3]将加权平均集成经验模态分解(Weighted Average Ensemble Empirical Mode Decomposition, WAEEMD)和 MSB 相结合,用于提取滚动轴承的故障特征;朱丹宸等^[4]将二阶全变分去噪与 MSB 相结合,对轴承进行诊断;TIAN 等^[5]对 MSB 进行改进,使其更加稳定,并且改进后的 MSB 适用于轴承故障的分类.

当前对弧齿锥齿轮故障诊断的研究基本是从振动信号中提取特征来对故障进行分析^[6-8],如扶碧波等^[6]使用 BP(Back Propagation)神经网络对弧齿锥齿轮的磨损状态进行识别;BUZZONI 等^[8]使用贝叶斯分类器对直齿锥齿轮的磨损、点蚀状态进行识别.然而,传统的故障模式识别方法难以有效地构建故障与信号之间复杂的映射关系^[9].随着卷积神经网络(Convolutional Neural Network, CNN)的发展,模式识别的准确率越来越高,数据挖掘能力也越来越强.近年来,CNN 在旋转机械^[10-12]故障诊断中得到初步的研究和应用.CNN 可以改善传统的故障模式识别算法的缺点,但如何基于振动信号构造弧齿锥齿轮故障样本是训练损伤程度识别 CNN 模型的关键,传统的时域及频域特征样本构造方法难以提取微弱故障特征.而 MSB 为高阶谱,能有效反映信号的微弱特征,且已有研究证明其适用于旋转机械的故障诊断.

本文将 MSB 与 CNN 相结合,采用弧齿锥齿轮振动信号的调制信号双谱图构造 CNN 的输入样本,提出基于调制信号双谱和卷积神经网络的弧齿锥齿轮损伤程度识别方法,并通过试验验证方法的有效性.

1 理论背景

1.1 MSB 理论

YANG 等^[13-14]的研究表明:MSB 有着强大的解调能力,且处于强噪声环境下也能够获取旋转机械的故障特征.MSB 是一种改进的双谱方法,同样由二阶功率谱延伸而来.离散时间振动信号 $x(t)$ 的傅里叶变换 $X(f)$ 为

$$X(f) = \text{DFT}[x(t)] = \sum_{t=-\infty}^{\infty} x(t) e^{-j2\pi ft}. \quad (1)$$

$x(t)$ 的 MSB 为

$$B_{\text{MS}}(f_c, f_x) = E[X(f_c + f_x) X(f_c - f_x) X^*(f_c) X^*(f_c)]. \quad (2)$$

式中: $B_{\text{MS}}(f_c, f_x)$ 为信号 $x(t)$ 的调制信号双谱; $X^*(f_c)$ 为 $X(f_c)$ 的共轭复数; $E[\]$ 为数学期望; f_c 为载波频率; f_x 为调制频率; $(f_c + f_x)$ 为上边带频率; $(f_c - f_x)$ 为下边带频率.

MSB 的幅值 $A_{\text{MS}}(f_c, f_x)$ 和相位 $\varphi_{\text{MS}}(f_c, f_x)$ 为

$$A_{\text{MS}}(f_c, f_x) = E[|X(f_c + f_x)| |X(f_c - f_x)| |X^*(f_c)| |X^*(f_c)|]; \quad (3)$$

$$\varphi_{\text{MS}}(f_c, f_x) = \varphi(f_c + f_x) + \varphi(f_c - f_x) - |\varphi(f_c)| - |\varphi(f_c)|. \quad (4)$$

MSB 边频带 $B_{\text{MS}}^{\text{SE}}(f_c, f_x)$ 的计算公式如式(5)所示.

$$B_{\text{MS}}^{\text{SE}}(f_c, f_x) = E\left[\frac{X(f_c + f_x) X(f_c - f_x) X^*(f_c) X^*(f_c)}{|X(f_c)|^2}\right]. \quad (5)$$

1.2 CNN 简介

典型的 CNN 包括输入层、卷积层、池化层、全连接层和输出层^[15],其网络结构如图 1 所示.

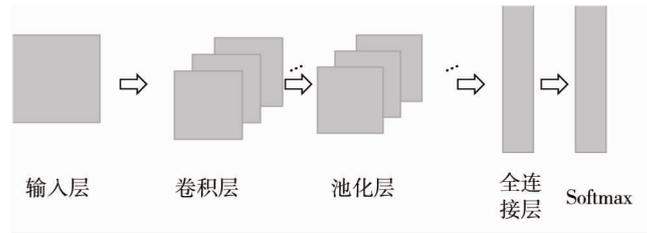


图 1 CNN 网络结构

1) 输入层:输入层的工作是对原始数据进行预处理操作,使处理后的数据更方便地用于试验,主要包括去均值与归一化。

2) 卷积层:卷积层是 CNN 的核心层次,它的作用是通过卷积操作提取数据的局部特征.卷积层的主要操作过程可以分为 2 步:一是将每个神经元看成是一个滤波器;二是根据设定的步长,使滤波器在数据矩阵上滑动,然后计算每一个窗口的特征值。

$$a_j^l = \sigma \left(\sum_{i \in M_j} a_i^{l-1} \times \omega_{ij}^l + b_j^l \right). \quad (6)$$

式中: a_j^l 为网络中第 l 层第 j 个卷积核的输出; a_i^{l-1} 为网络中第 $l-1$ 层第 i 个卷积核的输入; M_j 为输入特征图; ω_{ij} 为权重系数; b_j^l 为 l 层第 j 个卷积核的网络偏置; σ 为激活函数。

3) 池化层:池化层在每一层的卷积操作之后,它的主要目的是防止过拟合.每一层的数据经过池化之后,数据量会有有一定的减少,因为池化操作就是选取某一区域中数据的最大值或者平均值,从而压缩数据.池化层的作用是保持数据特征不变、特征降维和防止过拟合。

4) 全连接层:通常卷积神经网络的最后一层或两层是全连接层.全连接层是指两层之间所有神经元都是两两连接的,每一个神经元与下一层都是一对多的关系,这也导致全连接层的参数量大大增加,因此全连接层的层数一般也设置的较少.全连接层的作用是分类样本、标记样本和解决非线性问题。

$$h(\mathbf{X}) = \sigma'(\mathbf{b}' + \boldsymbol{\omega}'\mathbf{X}). \quad (7)$$

式中: $h(\mathbf{X})$ 为全连层的输出; \mathbf{X} 为特征向量; $\boldsymbol{\omega}'$ 为全连接层权重矩阵; \mathbf{b}' 为全连接层偏置向量; σ' 为全连接层的激活函数。

2 基于调制信号双谱和 CNN 的弧齿锥齿轮的损伤程度识别

基于调制信号双谱和 CNN 的弧齿锥齿轮损伤程度识别的流程如下:

步骤 1:开展弧齿锥齿轮故障振动测试试验,利用加速度传感器采集弧齿锥齿轮的振动信号,设置合适的采样频率,并采集足够的振动信号片段。

步骤 2:将采集的振动信号片段分割成若干等长度的数据片段并进行预处理与归一化处理,对其进行调制信号双谱分析,提取调制信号双谱的俯视图像构造特征图样本集,并将其划分为训练集和测试集。

步骤 3:初始化卷积神经网络的学习率 k 、池化层采样大小 s 、最小训练量 n 、卷积核尺寸 o 及迭代次数 m 等参数,并将这些参数构建为参数集 \mathbf{P} .分别设置学习率、迭代次数、最小训练量和卷积核尺寸,设置池化层采样大小的迭代回合阈值为 $x_1 \sim x_5$,调整步长为 $y_1 \sim y_5$ 。

步骤 4:将训练集输入 CNN 模型进行模型训练,优化选取迭代次数和学习率等关键参数,输入模型错误率最小的模型参数构建参数集 \mathbf{P} ,完成 CNN 模型训练。

步骤 5:将测试样本集输入训练好的 CNN 模型进行识别,检验模型的有效性,从而实现弧齿锥齿轮的损伤程度识别。

3 弧齿锥齿轮损伤故障试验

3.1 试验数据采集

为了验证本文方法的有效性,在弧齿锥齿轮系统故障综合模拟台上进行弧齿锥齿轮损伤故障振动模拟试验,弧齿锥齿轮减速箱如图 2 所示.根据损伤程度的不同,设置正常齿轮和 2 种不同程度的损伤故障

齿轮,3 种状态的弧齿锥齿轮如图 3 所示.由于故障齿轮设置在输入轴,加速度传感器安装在输入轴上.采用 BK 测试系统对正常状态与不同损伤程度状态的弧齿锥齿轮振动信号进行采集,采集正常齿轮状态、轻度损伤齿轮状态及中度损伤齿轮状态下的振动信号,采样频率为 3.2 kHz,转速为 900 r/min.



图 2 弧齿锥齿轮减速箱



图 3 3 种状态的弧齿锥齿轮

将每种状态下采集的振动信号分成若干长度为 1 024 的数据片段,对每个数据片段进行调制信号双谱分析,获得默认等视角下的调制信号双谱图如图 4 所示.为了观察到全部的特征分量,避免部分特征被遮挡导致特征丢失,将图 4 调整到俯视角状态,获得俯视角下的调制信号双谱图(图 5).并转化为 RGB 图像作为后续模型训练样本.

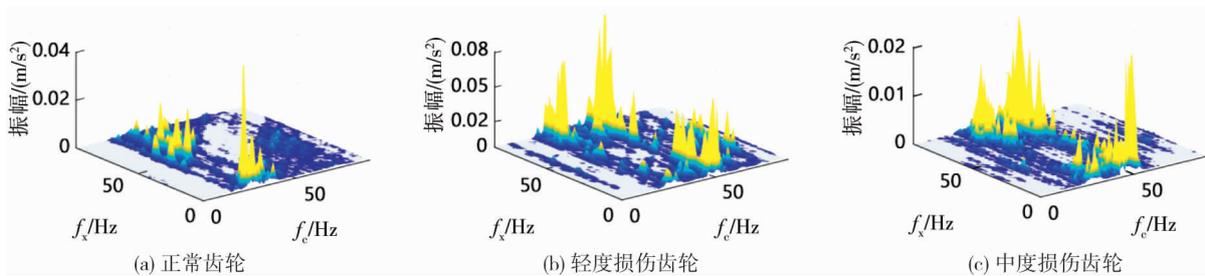


图 4 不同状态下弧齿锥齿轮等视角下的调制信号双谱图

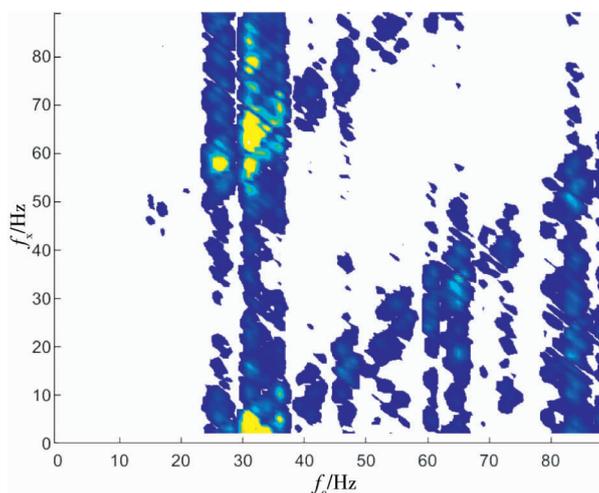


图 5 正常状态弧齿锥齿轮俯视角下的调制信号双谱图

3.2 CNN 模型构建与参数选择

所采用的卷积神经网络结构包含1个输入层、3个卷积层、2个最大池化层、1个展平层、2个全连接层和1个输出层,卷积神经网络的流程如下:(1)激活函数替换为 ReLU;(2)模型输入的特征图像尺寸调整为 $128 \times 128 \times 1$;(3)使用最大池化法,加快网络训练速度;(4)在卷积层后加入 BatchNorm 操作,加快网络收敛速度及稳定性;(5)全连接层加入 Dropout 操作,有效防止过拟合.卷积神经网络的架构如图6所示,具体参数见表1.

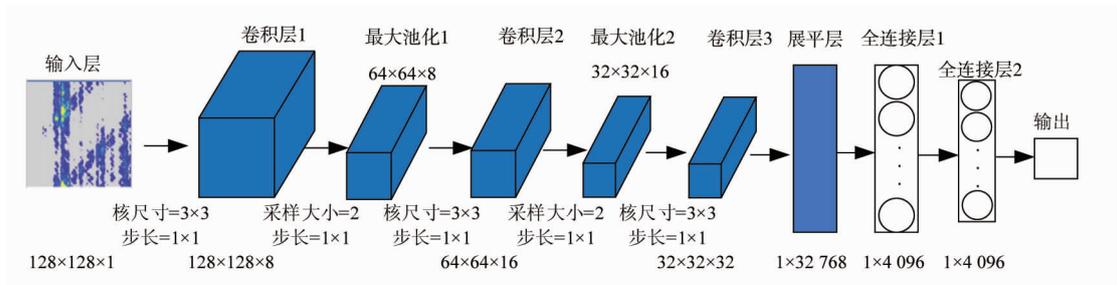


图6 卷积神经网络架构

表1 卷积神经网络具体参数

模型参数	特征图数	卷积核(采样)大小	步长	激活函数
输入层	1	-	-	-
卷积层 1	8	3×3	1×1	ReLU
池化层 1	8	2×2	1×1	-
卷积层 2	16	3×3	1×1	ReLU
池化层 2	16	2×2	1×1	-
卷积层 3	32	3×3	1×1	ReLU
展平层	1	-	-	-
全连接层 1	1	-	-	ReLU
全连接层 2	1	-	-	ReLU
输出层	1	-	-	Softmax

为了获取高精度的 CNN 诊断模型,选择合适的参数很重要.本文使用层次优化法^[16]选取 CNN 的主要参数:迭代次数为 90,学习速率为 0.000 1,每次训练的最小训练量为 50 个,卷积核尺寸为 3×3 ,池化层采样大小为 2×2 .将获得的 3 种不同状态弧齿锥齿轮的调制信号双谱图作为 CNN 输入样本,构建 MSB-CNN 故障诊断系统,其中每一种故障状态含 500 个样本,随机选取 150 个作为训练样本,其余 350 个作为测试样本.

3.3 弧齿锥齿轮故障识别结果及分析

为验证调制信号双谱的优势和有效性,试验选取振动信号+CNN 与调制信号双谱+CNN 的方法进行对比.不同输入样本的分类混淆矩阵如图7所示,其中 0, 1, 2 分别表示正常齿轮、轻度损伤齿轮、中度损伤齿轮.

预测类别 \ 真实类别	真实类别			准确率
	0	1	2	
0	350 33.3%	0 0.0%	0 0.0%	100%
1	0 0.0%	350 33.3%	1 0.1%	99.7%
2	0 0.0%	0 0.0%	349 33.2%	100%
总计	100%	100%	99.7%	99.9%

(a) 调制信号双谱+CNN

预测类别 \ 真实类别	真实类别			准确率
	0	1	2	
0	329 31.3%	1 0.1%	11 1.0%	96.5%
1	12 1.1%	318 30.3%	7 0.7%	94.4%
2	9 0.9%	31 3.0%	332 31.6%	89.2%
总计	94.0%	90.9%	94.9%	93.2%

(b) 振动信号+CNN

图7 不同输入样本的分类混淆矩阵

为了消除单次诊断存在的差异性问题,将每组试验重复运行 100 次,故障状态识别结果取重复试验的平均值,2 种方法的识别结果与模型训练时间如表 2 所示.由表 2 可知:调制信号双谱+CNN 方法的平均识别准确率为 99.91%,振动信号+CNN 方法的平均识别准确率低于本文方法.

表 2 识别结果与模型训练时间

故障识别方法	测试样本数	平均识别准确率/%	训练时间/s
调制信号双谱+CNN	1 050	99.91	67
振动信号+CNN	1 050	93.53	107

作为输入样本,振动信号是一维数据,信号中包含大量的噪声,所以平均识别准确率有所下降.MSB 不仅能有效处理信号的非线性成分,还能抑制各种噪声,使用 MSB 作为样本输入 CNN,提取的特征更加准确,所以平均识别准确率更高.

为进一步验证本文所提方法相较于其他智能故障识别方法的优势和有效性,试验选取调制信号双谱+SVM、调制信号双谱+BP 的识别结果进行比较.其中 SVM 采用 RBF 核函数,参数^[17-18]选取:核函数参数 $\delta=3$,惩罚因子 $C=4$,BP 神经网络隐含层节点数为 32,节点激活函数为 ReLU^[19].最近一次得到的测试集分类混淆矩阵如图 8 所示,其中 0, 1, 2 分别表示正常齿轮、轻度损伤齿轮、中度损伤齿轮.图 8 中的对角线为各类型信号的具体预测结果.

预测类别	0	349 33.2%	0 0.0%	0 0.0%	100% 0.0%
	1	1 0.1%	347 33.0%	1 0.1%	99.4% 0.6%
	2	0 0.0%	3 0.3%	349 33.2%	99.1% 0.9%
		99.7% 0.3%	99.1% 0.9%	99.7% 0.3%	99.5% 0.5%
		0	1	2	真实类别
(a) 调制信号双谱+SVM					
预测类别	0	318 30.3%	25 2.4%	12 1.1%	89.6% 10.4%
	1	15 1.4%	312 29.7%	25 2.4%	88.6% 11.4%
	2	17 1.6%	13 1.2%	313 29.8%	91.3% 8.7%
		90.9% 9.1%	89.1% 10.9%	89.4% 10.6%	89.8% 10.2%
		0	1	2	真实类别
(b) 调制信号双谱+BP					

图 8 不同识别方法的分类混淆矩阵

识别结果与模型训练时间如表 3 所示.由表 3 可知:调制信号双谱+CNN 的平均识别准确率为 99.91%,其他 2 种智能故障识别方法的平均识别准确率都低于本文方法;同样采样调制信号双谱作为模型输入样本,本文方法的训练时间为 97 s,远优于其他 2 种智能故障识别方法,大幅提升了故障识别的效率.

表 3 识别结果与模型训练时间

故障识别方法	测试样本数	平均识别准确率/%	训练时间/s
调制信号双谱+CNN	1 050	99.91	97
调制信号双谱+SVM	1 050	99.42	2 374
调制信号双谱+BP	1 050	89.37	621

在处理多分类问题时,SVM 因为分类器的构造原因,其模型较为复杂,训练速度较慢,且 SVM 的分类器只对其相同标签的样本数据进行训练^[20],导致 SVM 的训练和测试分类的速度较慢.采用调制信号双谱作为样本输入,SVM 提取的特征更加准确,因此平均识别准确率较高.而 BP 神经网络为浅层结构,处理非线性问题的能力有限,导致图像的部分特征不容易识别,限制了其识别故障信息的能力.卷积神经网络为深层结构,非线性处理能力强,且卷积神经网络中卷积层的权值共享机制使网络中可训练的参数变少,提升了训练效率,模型的平均识别准确率更高.

4 结论

1) 所构建的卷积网络模型以及调制信号双谱样本构造方法,将特征自动学习与故障分类相结合,弥补了传统故障识别方法需要人工提取特征的缺点,简化了诊断流程。

2) 与振动信号对比,调制信号双谱作为输入样本时,平均识别准确率更高。

3) 与传统智能故障识别方法相比,所提出的识别方法在平均识别准确率和模型训练时间上都具有优势。

参考文献:

- [1] JEDLIŃSKI Ł, JONAK J. A disassembly-free method for evaluation of spiral bevel gear assembly[J]. *Mechanical Systems and Signal Processing*, 2017, 88: 399-412.
- [2] 李加伟,张永祥,赵磊.基于频谱编辑和调制信号双谱的齿轮裂纹故障诊断[J]. *中国测试*, 2021, 47(2): 98-105.
- [3] 郭俊超,甄冬,孟召宗,等.基于WAEEMD和MSB的滚动轴承故障特征提取[J]. *中国机械工程*, 2021, 32(15): 1793-1800.
- [4] 朱丹宸,张永祥,赵磊,等.基于TVD和MSB的滚动轴承故障特征提取[J]. *振动与冲击*, 2019, 38(8): 103-109.
- [5] TIAN X G, GU J X, REHAB I, et al. A robust detector for rolling element bearing condition monitoring based on the modulation signal bispectrum and its performance evaluation against the Kurtogram[J]. *Mechanical Systems and Signal Processing*, 2018, 100: 167-187.
- [6] 扶碧波,方宗德,沈云波.基于小波神经网络弧齿锥齿轮故障诊断及实验研究[J]. *机械传动*, 2011, 35(12): 66-69.
- [7] 何水龙,訾艳阳,万志国,等.自适应提升多小波在螺旋伞齿轮故障诊断中的应用[J]. *仪器仪表学报*, 2014, 35(1): 148-153.
- [8] BUZZONI M, D'ELIA G, MUCCHI E, et al. A vibration-based method for contact pattern assessment in straight bevel gears[J]. *Mechanical Systems and Signal Processing*, 2019, 120: 693-707.
- [9] 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.
- [10] ZHANG W, LI C H, PENG G L, 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.
- [11] CHEN Z Q, LI C, SANCHEZ R V. Gearbox fault identification and classification with convolutional neural networks[J]. *Shock and Vibration*, 2015, 2015: 390134.
- [12] LIU C, CHENG G, CHEN X H, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. *Sensors*, 2018, 18(5): 1523.
- [13] YANG W X, LITTLE C, COURT R. S-Transform and its contribution to wind turbine condition monitoring[J]. *Renewable Energy*, 2014, 62: 137-146.
- [14] SUN H L, ZI Y Y, HE Z J. Wind turbine fault detection using multiwavelet denoising with the data-driven block threshold[J]. *Applied Acoustics*, 2014, 77: 122-129.
- [15] 李彦冬,郝宗波,雷航.卷积神经网络研究综述[J]. *计算机应用*, 2016, 36(9): 2508-2515.
- [16] 陶洁,刘义伦,付卓,等.基于Teager能量算子和深度置信网络的滚动轴承故障诊断[J]. *中南大学学报(自然科学版)*, 2017, 48(1): 61-68.
- [17] 李东,刘广璞,黄晋英,等.基于EEMD-SVD与SVM的轴承故障诊断[J]. *机械设计与研究*, 2019, 35(6): 123-127.
- [18] 侯平智,唐飞平,吴锋.基于SVM算法的环锭纺纱机钢丝圈故障诊断[J]. *杭州电子科技大学学报(自然科学版)*, 2017, 37(4): 47-52.
- [19] 贾京龙,余涛,吴子杰,等.基于卷积神经网络的变压器故障诊断方法[J]. *电测与仪表*, 2017, 54(13): 62-67.
- [20] 袁胜发,褚福磊.支持向量机及其在机械故障诊断中的应用[J]. *振动与冲击*, 2007, 26(11): 29-35.