

DOI: 10.13382/j.jemi.B2105065

基于特征融合与 ResNet 的行星齿轮箱故障诊断*

魏秀业^{1,2} 程海吉² 贺 妍^{1,2} 赵 峰² 贺全玲²

(1. 中北大学先进制造技术山西省重点实验室 太原 030051; 2. 中北大学机械工程学院 太原 030051)

摘 要:针对行星齿轮箱振动信号相互耦合和故障诊断不准确等问题,提出一种基于特征融合与深度残差网络(ResNet)的行星齿轮箱故障诊断方法。首先,对采集到的行星轮裂纹、磨损,太阳轮断齿及复合故障等模拟故障振动信号应用多维集成经验模态分解(MEEMD)和VMD进行分解,分别筛选确定有效分量。然后,将筛选出的有效特征进行融合,分别应用传统卷积神经网络(CNN)和深度残差网络对其进行分类识别。结果发现,深度残差网络,分类准确度更高,可达95%以上。最后,应用深度残差对特征融合前后数据的分类准确度进行了比较。融合前准确度最高只达91.16%,低于融合的97.18%。可见,该方法对行星齿轮箱耦合振动信号的处理和故障诊断非常有效。

关键词:多维集成经验模态分解;VMD;卷积神经网络;深度残差网络;行星齿轮箱;故障诊断

中图分类号: TN10;TH165+.3 **文献标识码:** A **国家标准学科分类代码:** 460

Fault diagnosis of planetary gearboxes based on feature fusion and ResNet

Wei Xiuye^{1,2} Cheng Haiji² He Yan^{1,2} Zhao Feng² He Quanling²

(1. Shanxi Key Laboratory of Advanced Manufacturing Technology, North University of China, Taiyuan 030051, China;
2. School of Mechanical Engineering, North University of China, Taiyuan 030051, China)

Abstract: Aiming at the coupling of vibration signals and inaccurate fault diagnosis of planetary gearbox, a fault diagnosis method of planetary gearbox based on feature fusion and ResNet is proposed. Firstly, the collected analog fault vibration signals such as planetary gear crack, wear, sun gear broken tooth and composite fault are decomposed by MEEMD and VMD to screen and determine the effective components respectively. Then, the selected effective features are fused and classified by using traditional CNN network and ResNet. The results show that the ResNet has higher classification accuracy, up to more than 95%. Finally, the classification accuracy of data before and after feature fusion is compared by using ResNet. The accuracy before fusion was only 91.16%, which was lower than 97.18% of after fusion. Thus, this method is very effective for coupling vibration signal processing and fault diagnosis of planetary gearbox.

Keywords: multi-dimensional ensemble empirical mode decomposition(MEEMD); visual merchandise design(VMD); CNN; ResNet; planetary gearbox; fault diagnosis

0 引 言

行星齿轮箱具有传动比大和承载能力强的优点,已广泛应用于能源、航空航天等领域设备的传动系统中,同时其生产的安全、高效问题也倍受关注^[1]。由于行星齿轮箱传动结构复杂,且工作时不同相位齿轮啮合的振动

相互耦合^[2-3],使得其故障特征提取困难,故障诊断难度增加。针对此问题,祝文颖等^[4]提出了基于改进经验小波变化的方法;罗奕等^[5]提出了基于声信号的包络分析方法;赵磊等^[6]与李伟等^[7]也分别提出了不同的信号处理方法;郑近德等^[8-9]研究了多维集成经验模态分解(multi-dimensional ensemble empirical mode decomposition, MEEMD)方法和VMD(visual merchandise design)分解方

法,在信号处理领域取得了重大突破。但这些方法没有结合深度学习的优势进行进一步研究。

近年来基于深度学习的故障诊断方法已成为机械设备健康管理领域的研究热点。现阶段深度学习比传统的机器更受欢迎。Xia 等^[10]、Yu^[11]和陈星^[12]提出了不同的深度学习算法。针对行星齿轮箱故障诊断,孙灿飞等^[13]研究了生成式对抗网络的方法;胡葛庆等^[14]提出了基于经验模态分解和深度卷积神经网络的方法;孔子迁等^[15]研究了基于时频融合和注意力机制的深度学习的方法;熊鹏等^[16]提出了基于动态加权密集连接卷积网络的变转速故障诊断方法;Ren 等^[17]提出了基于 VMD-MPE 和基于特征的迁移学习方法。这些方法没有很好解决深度学习数据量不足的问题。

本文以行星齿轮箱为监测对象,研究基于特征融合与深度残差网络的行星齿轮箱故障诊断方法。首先,对行星齿轮箱模拟故障实验采集到的混叠振动信号进行 MEEMD 和 VMD 分解,提取特征实现数据扩容,采用相关系数和方差贡献率确定有效分量。在此基础上调试两种卷积神经网络(CNN)模型,即传统 CNN 模型和深度残差网络(ResNet)模型。将融合特征输入调试好的网络结构中,输出分类结果。对比两种网络结构诊断准确率、收敛速度、损失效果等。设置特征融合前后分类准确度进行对照,验证了特征融合与深度残差网络的行星齿轮箱故障诊断方法的有效性。解决了深度残差网络单独使用数据量不足,输入网络样本特征不明显的问题。

1 理论基础

1.1 MEEMD 和 VMD 算法

为了有效地消除模态混叠现象,减少重构误差。本文采用了 MEEMD 方法。

VMD 通过训练次数搜索变分模态型中最优解,将原始信号分解成 K 个固有模态(IMF)离散的有效分离,并自适应地匹配每种模态的最佳中心频率和有限带宽。因此本文采用 VMD 算法进行信号处理。

1.2 深度学习理论基础

1) 卷积层、池化层、全连接层

卷积是采用某种方式将一个函数“应用”到另一个函数。公式为:

$$y(t) = x(t) * h(t) = \int_{-\infty}^{\infty} x(x)h(t-x)dx \quad (1)$$

池化层可以被认为是由间隔为 s 个像素的池单元网格组成,每个池汇总了以池单元的位置为中心的大小为 $z \times z$ 的邻域。

全连接层是一个传统的多层感知器,它在输出层使用 Softmax 等激活函数。

2) Dropout

为了防止过拟合,提升模型泛化能力,传统 CNN 一般在全连接层加入 Dropout。结构如图 1 所示。




图 1 非 Dropout 与 Dropout 结构图

Fig. 1 Undropout and dropout structure diagram

3) 残差块

深度残差网络(ResNet)的基础块,即为残差块(residual block)。在残差块中,输入可通过跨层的数据,线路更快地向前传播。路径分为“Shortcut Path”和“Main Path”,在残差块中,为了加速训练的速度加入了 Batch 正则化“Batch Norm”。

2 行星齿轮传动部分模拟故障实验

2.1 实验系统组成及测点布置

在实验室开展了故障模拟实验。搭建了如图 2 所示的故障诊断实验台,对不同故障状态的振动加速度信号(单位为 m/s^2)进行了采集。




图 2 行星齿轮箱实验台

Fig. 2 Planetary gearbox test bed

实验采样时将电机的转速调整到 1 500 rpm,采样频率设置为 10.24 kHz,设置负载为 0.3 A。检查测点信号是否正常,由于模拟复杂工作工况,考虑齿轮不能长时间带故障工作,所以设置采样稳定状态下 10 s 数据。

本次实验采集的振动加速度信号,除正常工况外,重点设置 4 种行星齿轮箱模拟故障,分别为行星轮裂纹,行星轮磨损,太阳轮断齿,太阳轮齿面磨损与行星轮齿面点蚀复合工况(5 种工况分别简化为工况 1~工况 5),实物照片如图 3 所示。

实验时,使用信号采集仪连接电脑,用 DASP 采集系




图 3 故障零件实物照片
Fig. 3 Physical photos of faulty parts

统进行信号采集。依次更换故障齿轮,对 4 种故障工况的振动信号进行采集。实验室现场测试测点布置照片如图 4 所示。在实验台共布置 11 个测点,测点位置如图 5 所示。



图 4 行星齿轮箱实验台现场测点布置图
Fig. 4 Layout of measuring points on the planet gearbox test platform




图 5 行星齿轮箱测点布置示意图
Fig. 5 Schematic diagram of planetary gearbox measuring point layout

2.2 分解信号筛选有效分量

对上节采集到的 5 种工况下的行星齿轮箱振动信号按照每 0.1 s(采样点数为 1 024)进行分段,即得到 11 个测点 5 种工况总计 5 500 个样本。然后分别运用 MEEMD 和 VMD 分解得到多个 IMF 分量。在 5 种工况 11 个测点数据中随机以正常工况和太阳轮断齿工况的 10 测点数据为例,其信号分解情况如图 6、7、8、9 所示。

由分解图可以直观看出各 IMF 分量与原始信号的相关程度,每一个 IMF 分量代表了原始信号中存在的一种内涵模态分量,最后一阶分量为残差。但要想得到真实准确有效分量特征,需从定量角度去分析筛选。

分解得到的 IMF 分量,采用相关系数和方差贡献率进行筛选包含主要故障的分量。原始信号与非真实分量的相关系数较小,方差贡献率低。随机以各工况下测点




图 6 正常工况 MEEMD 分解图
Fig. 6 MEEMD decomposition diagram of normal working conditions




图 7 正常工况 VMD 分解图

Fig. 7 VMD decomposition diagram of normal working conditions






图 9 太阳轮断齿 VMD 分解图

Fig. 9 VMD Decomposition diagram of broken teeth of sun gear



(a) IMF1~5



(b) IMF6~10

图 8 太阳轮断齿 MEEMD 分解图

Fig. 8 MEEMD decomposition diagram of broken teeth of sun gear

1~3 原始信号与各 IMF 分量的相关系数和方差贡献率为例,数据展示如表 1、2、3、4 所示。

根据文献[18]知相关系数 $|r| \leq 0.3$ 、 $0.3 < |r| \leq 0.5$ 、 $0.5 < |r| \leq 0.8$ 、 $|r| > 0.8$ 分别表示:不存在相关性、低度相关性、显著相关性;高度相关性。通过分析研究各分量与原始信号数据相关系数的大小,发现 MEEMD 分解信号各工况下原始信号与 IMF4 之前分量的相关系数均大于 0.3,发现 VMD 分解信号各工况下原始信号与 IMF2 之前分量的相关系数均大于 0.3,由此初步判断,MEEMD 分解信号的前 4 个 IMF 分量为和 VMD 分解信号的前 2 个 IMF 分量为真实分量。接着进一步通过方差贡献率进行确定有效分量。

从表 2 MEEMD 分解出各分量的方差贡献率显示,其前 4 阶分量的方差贡献率均大于 0.01,且每种工况前 4 阶分量的方差贡献率和均大于 0.98;IMF6~10 的方差贡献率和不足 0.01,由于篇幅受限不再列出。由此判定 MEEMD 分解出的前 4 阶分量为有效分量。

VMD 分解共 4 阶分量,方差贡献率和为 1,平均分量的方差贡献率为 0.25。从表 4 VMD 分解出各分量的方差贡献率显示,前两阶分量均大于平均值,后两阶分量的方差贡献率小于平均值。结合 VMD 分量与原始信号的相关性大小,判定 VMD 分解出的前两阶分量为有效分量。

表 1 MEEMD 各分量与原始数据相关系数表

Table 1 Relation between MEEMD components and original data

工况	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6~10
1	0.878 6	0.472 4	0.367 7	0.314 8	0.103 7	...
	0.833 8	0.405 8	0.348 2	0.336 0	0.151 0	...
	0.866 6	0.436 4	0.356 7	0.329 8	0.153 7	...
	0.873 4	0.402 8	0.399 6	0.350 1	0.136 6	...
2	0.815 0	0.439 1	0.459 6	0.398 4	0.181 1	...
	0.836 4	0.457 8	0.374 6	0.338 1	0.157 6	...
	0.876 0	0.520 0	0.361 6	0.355 4	0.144 9	...
	0.869 0	0.409 4	0.395 8	0.383 3	0.158 4	...
3	0.849 0	0.535 0	0.458 6	0.357 4	0.146 9	...
	0.890 4	0.546 0	0.461 5	0.352 7	0.164 1	...
	0.847 2	0.599 9	0.461 0	0.346 8	0.151 4	...
	0.844 4	0.558 0	0.453 5	0.337 7	0.127 1	...
4	0.848 6	0.403 3	0.397 8	0.338 9	0.156 6	...
	0.815 0	0.678 3	0.402 6	0.358 7	0.174 7	...
	0.824 6	0.547 3	0.457 8	0.348 9	0.157 6	...

表 2 MEEMD 各分量方差贡献率表

Table 2 Variance contribution rates of MEEMD components

工况	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6~10
1	0.760 2	0.130 7	0.074 7	0.014 1	0.001 3	...
	0.703 8	0.181 8	0.085 8	0.010 6	0.001 0	...
	0.746 6	0.120 5	0.086 4	0.029 8	0.003 7	...
	0.783 4	0.050 1	0.092 8	0.050 1	0.006 6	...
2	0.711 0	0.080 4	0.099 1	0.098 4	0.001 1	...
	0.731 4	0.135 0	0.077 8	0.038 1	0.007 6	...
	0.746 0	0.102 7	0.080 0	0.055 4	0.004 9	...
	0.769 0	0.049 1	0.080 0	0.083 3	0.008 4	...
3	0.747 0	0.103 3	0.075 0	0.057 4	0.006 9	...
	0.797 4	0.058 8	0.076 0	0.052 7	0.004 1	...
	0.748 2	0.092 7	0.099 9	0.046 8	0.001 4	...
	0.747 4	0.121 8	0.068 0	0.037 7	0.007 1	...
4	0.743 6	0.111 6	0.083 3	0.038 9	0.006 6	...
	0.719 0	0.138 3	0.068 3	0.058 7	0.004 7	...
	0.725 6	0.100 6	0.097 3	0.048 9	0.007 6	...

表 3 VMD 各分量与原始数据相关系数表

Table 3 Relation between VMD components and original data

工况	IMF1	IMF2	IMF3	IMF4
1	0.898 6	0.472 4	0.2677	0.094 8
	0.703 8	0.405 8	0.248 2	0.136 0
	0.746 6	0.436 4	0.256 7	0.129 8
	0.883 4	0.402 8	0.299 6	0.050 1
2	0.811 0	0.439 1	0.259 6	0.098 4
	0.831 4	0.457 8	0.274 6	0.138 1
	0.846 0	0.520 0	0.261 6	0.155 4
	0.869 0	0.409 4	0.205 8	0.083 3
3	0.847 0	0.535 0	0.258 6	0.057 4
	0.897 4	0.446 0	0.261 5	0.052 7
	0.848 2	0.599 9	0.261 0	0.046 8
	0.747 4	0.458 0	0.253 5	0.137 7
4	0.743 6	0.403 3	0.297 8	0.038 9
	0.819 0	0.378 3	0.202 6	0.058 7
	0.725 6	0.447 3	0.257 8	0.148 9

表 4 VMD 方差贡献率表

Table 4 Variance contribution rates of VMD components

工况	IMF1	IMF2	IMF3	IMF4
1	0.556 7	0.372 4	0.056 1	0.014 8
	0.503 8	0.305 8	0.174 4	0.016 0
	0.546 6	0.336 4	0.097 2	0.019 8
	0.583 4	0.302 8	0.103 7	0.010 1
2	0.511 0	0.339 1	0.131 5	0.018 4
	0.531 4	0.357 8	0.092 7	0.018 1
	0.546 0	0.320 0	0.108 6	0.025 4
	0.569 0	0.309 4	0.098 3	0.023 3
3	0.547 0	0.335 0	0.100 6	0.017 4
	0.597 4	0.346 0	0.033 9	0.022 7
	0.548 2	0.396 9	0.028 1	0.026 8
	0.547 4	0.358 0	0.076 9	0.017 7
4	0.543 6	0.303 3	0.114 2	0.038 9
	0.518 0	0.378 3	0.065 0	0.038 7
	0.425 6	0.347 3	0.188 2	0.038 9

由此,将筛选出的各工况 MEEMD 分解的 4 阶有效分量和 VMD 分解的 2 阶有效分量进行特征融合形成新的样本,使得每一条数据实现了 6 倍扩容。这样不仅抑制了模态混叠现象,实现了数据的预处理,提取出更为有效的故障信息,而且缓解了恶劣工作环境采集故障信号的困难。

整理特征数据,即 $5 \times 11 \times 600 = 33\ 000$ 个特征,通过单通道输入卷积神经网络结构当中,进行训练测试。

3 CNN 网络结构的建立与诊断结果分析

3.1 CNN 网络模型建立

1) 传统 CNN 网络模型建立

传统 CNN 模型在此设置为由 3 个卷积层和两个全连接层组成的 5 层神经网络。使用 ReLU 非线性激活函数,采用最新的 Dropout。网络结构参数设置如表 5 所示。

表 5 传统卷积神经网络结构参数设置

Table 5 The structure parameter setting of traditional CNN

模块名称	内核数量	内核大小	步长
Conv1	96	11	4
Pool1		5	2
Conv2	128	5	1
Pool2		3	2
Conv3	384	3	2
Pool3		3	2

2) 深度残差网络模型的建立

深度残差网络与传统 CNN 网络不同之处是引入了

跳跃连接,提高了信息流通,并且也避免了梯度消失和网络退化。残差块中 Conv 的过滤器大小设为 (3×1) ,维数为 64,应用 ReLU 激活函数。深度残差网络结构图如图 10 所示,利用 BN 和全局平均池化进行正则化,加快了训练速度。




图 10 深度残差网络结构

Fig. 10 The structure chart of depth residual network

3.2 两种网络结构诊断结果与分析

1) 传统 CNN 网络结构诊断结果与分析

分别将 5 类工况共 33 000 个融合特征,随机输入调试好的传统 CNN 和深度残差网络中进行分类识别诊断,设置训练集与测试集比例为 4 : 1,即训练集为 26 400 个特征,测试集为 6 600 个特征。

网络训练过程中诊断准确度与迭代次数变化关系如图 11 所示,反复调试,发现将学习速率调试设置为 0.001, 'Max Epochs' 设置为 3, 'Mini Batch Size' 设置为 16,效果最好。当迭代次数为 4 950 时,准确率达到 90.5%。损失函数与迭代次数变化关系如图 12 所示,在迭代的 1 000 次内,损失函数下降速度较快,由 1.8 下降到 0.4,之后收敛速度逐渐减慢。

测试集输入网络前散点图如图 13 所示,可见样本点散乱,根本识别不出故障类别。随机选取一组传统 CNN 网络预测结果,如图 14 所示。经过反复测试发现平均准确率为 90.5%。传统 CNN 分类后的聚类图如图 15 所示,5 种故障类别基本可以识别出来。

2) 深度残差网络结构诊断结果与分析

对于同样的测试样本,采用与 3.2 节 1) 中同样的采样设置,运用深度残差网络进行诊断,其诊断的准确度与迭代次数关系如图 16 所示。

可见,深度残差网络诊断准确率上升速度明显超过




图 11 传统 CNN 准确度与迭代次数关系曲线

Fig. 11 The relationship cure between accuracy and iteration by traditional CNN




图 12 传统 CNN 损失函数与迭代次数关系曲线

Fig. 12 The relationship cure between loss function and iteration by traditional CNN




图 13 测试集输入网络前散点图

Fig. 13 The scatter diagram before test set input network




图 14 传统 CNN 网络预测结果

Fig. 14 The prediction results of traditional CNN




图 15 传统 CNN 分类后聚类图

Fig. 15 The classifies the compressed cluster graph of test by the traditional CNN




图 16 深度残差网络准确度与迭代次数关系曲线

Fig. 16 The relationship curve of between accuracy and iterations by depth residual network

了传统 CNN 网络,在迭代 3 000 次时,准确度已达到 90%;当 5 000 次,准确度几乎达到 100%。

损失函数与迭代次数关系如图 17 所示,明显损失函数下降速度要比传统 CNN 网络更快,最终损失函数降为

0.05,效果优于传统 CNN 网络。随机选取一组深度残差网络预测结果如图 18 所示。




图 17 深度残差网络损失函数与迭代次数关系曲线

Fig. 17 The relationship cure between loss function decline and iteration by deep residual network




图 18 深度残差网络预测结果

Fig. 18 The prediction results of deep residual network

深度残差网络诊断结果的分类图如图 19 所示,可见 5 种工况类别分明,清晰可见。反复实验发现平均准确度可以达到 97.18%。此外如果训练特征继续增加,诊断准确率还会更高。




图 19 深度残差网络分类结果

Fig. 19 The classification result diagram by deep residual network

通过以上研究结果显示,深度残差网络较传统 CNN 网络,诊断准确率大大提高,且收敛速度加快,损失效果更明显。因此选用深度残差网络进行行星齿轮箱的故障诊断。

3.3 诊断结果对比分析

为了对比分析,分别将原始数据($5\times11\times100=6\,600$ 个分段样本)、MEEMD 分解筛选后的 4 个有效分量特征($5\times11\times400=26\,400$ 个特征)以及 VMD 分解筛选后的两个有效分量特征, ($5\times11\times200=13\,200$ 个特征),输入调试好的深度残差网络中进行诊断。

设置训练集与测试集比例为 4 : 1,测试诊断分类概率混淆矩阵如图 20~22 所示。通过混淆矩阵分类概率得知,特征融合前数据均有明显的分类偏差,故障分类准确度基本低于正常工况准确度。而 3.2 节研究表明融合特征输入深度残差网络中平均分类诊断准确率高达 97.18%,测试诊断分类概率混淆矩阵如图 23 所示。




图 20 原始数据的分类概率
Fig. 20 The classification probability of raw data




图 21 MEEMD 筛选特征的分类概率
Fig. 21 The classification probability of MEEMD screening features

各数据分类准确率对比结果如图 24 所示,可见原始数据、MEEMD 筛选分量特征以及为 VMD 筛选特征的平均诊断准确率分别为 89.94%、92.42%和 91.16%,均低于融合特征的准确率。

对于同样的故障诊断实验台,本文提出的方法与文献[19]提出的“ALNAFSA-BP 模型”进行比较,该文献针对行星齿轮的磨损、裂纹及复合故障,在小样本的情况下




图 22 VMD 筛选特征的分类概率
Fig. 22 The classification probability of VMD screening features




图 23 融合特征的分类概率
Fig. 23 The classification probability of fused features




图 24 各数据平均分类准确度
Fig. 24 The average classification accuracy of each data

诊断准确度最高只达到了 95%。同样与文献[20]提出的“基于 PSO-FC 优化 KPCA 的行星齿轮磨损故障的识别方法”进行比较,该文献针对行星轮多种磨损故障,虽然诊断准确率达到 97%以上,但此准确度也是基于小样本和数据量少的情况下达到的。而本文方法的训练样本为 26 400。平均诊断准确度达到了 97.18%。3 种方法准确率对比结果如表 6 所示。

综上所述,MEEMD 筛选特征和 VMD 筛选特征融合组成的新特征,在深度残差网络中可以达到很高的分类准确率,通过对比验证该方法真实有效。

表 6 行星齿轮箱故障诊断不同方法准确度对比表
Table 6 The accuracy comparison of different methods

方法	ALNAFSA-BP	PSO-FC 优化	特征融合与
	模型 ^[19]	KPCA 法 ^[20]	ResNet 法
诊断准确率/%	95	97.5	97.18
训练样本数量	60	120	26 400
测试样本数量	40	80	6 600

4 结 论

应用 MEEMD 和 VMD 分别对采集到的振动信号自适应地分解出若干个 IMF 分量,并采用相关系数和方差贡献率筛选了有效分量,不仅将噪声干扰信号有效地区分,准确提取有效故障信息,抑制了模态混叠现象,提高分类故障准确度,而且还实现了数据扩容,缓解了采集故障数据困难的问题。应用传统 CNN 网络和深度残差网络对融合特征进行识别诊断,结果表明,深度残差网络分类准确度高优于 CNN,且损失函数效果更好。因此,将深度残差网络用于行星齿轮箱故障诊断更为科学。基于特征融合与深度残差网络的行星齿轮箱故障诊断方法,极大程度的解决了行星齿轮箱,故障信号采集困难,振动信号相互耦合和故障诊断不准确等问题。与最新的基于人工鱼群和粒子群优化模型的行星齿轮箱故障诊断方法相比,在样本量大幅增加条件下,诊断准确度明显提高。特别是利用特征融合解决了深度残差网络用于齿轮箱故障诊断领域数据量不足,输入网络特征不明显的问题。

参考文献

[1] 隆勇,郭瑜. 基于加窗振动分离和变分模态分解的行星轮故障特征提取[J]. 电子测量与仪器学报,2019,33(2):18-24.

LONG Y, GUO Y. Fault feature extraction of the planet gear based on windowed vibration separation and variational mode decomposition [J]. Journal of Electronic Measurement and Instrumentation , 2019, 33(2):18-24.

[2] LIANG X, ZUO M, FENG Z. Dynamic modeling of gearbox faults: A review [J]. Mechanical Systems and Signal Processing, 2018 (98): 852-876.

[3] 杨之含,王少红,马超. 单级行星齿轮箱行星轮故障动力学分析[J]. 电子测量与仪器学报,2020,34(1):156-162.

YANG ZH H, WANG SH H, MA CH. Characteristics of single-stage planetary gearbox under crack failure [J]. Journal of Electronic Measurement and Instrumentation, 2020,34(1):156-162.

[4] 祝文颖,冯志鹏. 基于改进经验小波变换的行星齿轮箱故障诊断[J]. 仪器仪表学报,2016,37(10):

2193-2201.

ZHU W Y, FENG ZH P. Fault diagnosis of planetary gearbox based on improved empirical wavelet transform [J]. Chinese Journal of Scientific Instrument ,2016,37(10):2193-2201.

[5] 罗奕,郭瑜,伍星,等. 基于声发射信号的行星轮轴承内圈故障包络分析方法[J]. 电子测量与仪器学报,2019,33(5):164-170.

LUO Y, GUO Y, WU X, et al. Envelope analysis scheme for inner race fault planetary bearing based on acoustic emission signal [J]. Journal of Electronic Measurement and Instrumentation,2019,33(5):164-170.

[6] 赵磊,郭瑜,伍星. 基于包络加窗同步平均的行星齿轮箱特征提取[J]. 振动. 测试与诊断,2019,39(2):320-326,444.

ZHAO L, GUO Y, WU X. Feature extraction of planetary gearbox based on envelope windowed synchronous average[J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2):320-326,444.

[7] 李伟. 基于 EEMD 和 Teager 能量算子的行星齿轮箱故障特征提取研究[J]. 噪声与振动控制,2020,40(4):109-113,119.

LI W. Research on fault feature extraction of the planetary gear box based on EEMD and teager energy operator [J]. Noise and Vibration Control,2020,40(4):109-113,119.

[8] 郑近德,程军圣,杨宇. 改进的 EEMD 算法及其应用研究[J]. 振动与冲击,2013,32(21):21-26,46.

ZHENG J D, CHNG J SH, YANG Y. Modified EEMD algorithm and its applications [J]. Journal of Vibration and Shock,2013,32(21):21-26,46.

[9] 郑近德,姜伟伟,代俊习,等. 基于 VMD 的自适应复合多尺度模糊熵及其在滚动轴承故障诊断中的应用[J]. 航空动力学报,2017,32(7):1683-1689.

ZHENG J D, JIANG ZH W, DAI J X, et al. VMD based adaptive composite multiscale fuzzy entropy and its application to fault diagnosis of rolling bearing [J]. Journal of Aerospace Power,2017,32(7):1683-1689.

[10] XIA M, DE SILVA C W. Gear transmission fault classification using deep neural networks and classifier level sensor fusion[J]. Instrumentation, 2019,6(2):101-109.

[11] YU J. A selective deep stacked denoising autoencoders ensemble with negative correlation learning for gearbox fault diagnosis[J]. Computers in Industry, 2019,108:62-72.

[12] 陈星. 基于卷积神经网络算法的飞机发电机故障诊断研究[J]. 国外电子测量技术,2020,39(11):57-60.

- CHEN X. Fault diagnosis of aircraft generator based on convolution neural network algorithm [J]. Foreign Electronic Measurement Technology, 2020, 39 (11): 57-60.
- [13] 孙灿飞,王友仁,夏裕彬. 基于 SCAE-ACGAN 的直升机行星齿轮裂纹故障诊断[J]. 振动. 测试与诊断, 2021, 41(3):495-502,620-621.
- SUN C F, WANG Y R, XIA Y B. Crack fault diagnosis of helicopter planetary gear based on SCAE-ACGAN [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(3):495-502,620-621.
- [14] 胡芑庆,陈徽鹏,程哲,等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7):9-18.
- HU Y Q, CHEN H P, CHENG ZH, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks [J]. Journal of Mechanical Engineering, 2019, 55(7):9-18.
- [15] 孔子迁,邓蕾,汤宝平,等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法[J]. 仪器仪表学报, 2019, 40(6):221-227.
- KONG Z Q, DENG L, TANG B P, et al. Fault diagnosis of planetary gearbox based on deep learning with time-frequency fusion and attention mechanism [J]. Chinese Journal of Scientific Instrument, 2019, 40 (6): 221-227.
- [16] 熊鹏,汤宝平,邓蕾,等. 基于动态加权密集连接卷积网络的变转速行星齿轮箱故障诊断[J]. 机械工程学报, 2019, 55(7):52-57.
- XIONG P, TANG B P, DENG L, et al. Fault diagnosis for planetary gearbox by dynamically weighted densely connected convolutional networks [J]. Journal of Mechanical Engineering, 2019, 55(7):52-57.
- [17] REN H, LIU W, SHAN M. A new wind turbine health condition monitoring method based on VMD-MPE and feature-based transfer learning [J]. Measurement, 2019, 148: 106906-106913.
- [18] 杨东,宋汉江,霍柏琦,等. 基于特征相关分析的柴油机故障诊断方法研究[J]. 现代制造工程, 2018(12): 147-152,5.
- YANG D, SONG H J, HUO B Q, et al. Research on diesel engine fault diagnosis based on feature correlation analysis [J]. Modern Manufacturing Engineering, 2018(12):147-152,5.
- [19] 程海吉,魏秀业,张宁,等. 基于 ALNAFSA 优化 BP 神经网络的行星齿轮箱故障诊断[J]. 煤矿机械, 2021, 42(1):143-146.
- CHENG H J, WEI X Y, ZHANG N, et al. Fault diagnosis of planetary gearbox based on improved fish swarm algorithm optimization neural network [J]. Coal Mine Machinery, 2021, 42(1):143-146.
- [20] HE Y, YE L, ZHU X, et al. Feature extraction based on PSO-FC optimizing KPCA and wear fault identification of planetary gear [J]. Journal of Mechanical Science and Technology, 2021, 35(6): 1-11.

作者简介



魏秀业, 1987 年于山西矿业学院获得学士学位, 2003 年于太原理工大学获得硕士学位, 2009 年于中北大学获得博士学位, 现为中北大学副教授, 主要研究方向为机械故障诊断、进化算法。

E-mail: 704276365@qq.com

Wei Xiuye received her B. Sc. degree from Shanxi Mining Institute in 1987, M. Sc. degree from Taiyuan University of Technology in 2003 and Ph. D. degree from North University of China in 2009, respectively. Now she is an associate professor in North University of China. Her main research interests include mechanical fault diagnosis and evolutionary algorithms.