

DOI: 10.19650/j.cnki.cjsi.J2107612

基于电压信号深度特征学习的谐波减速器健康状态识别*

陈仁祥¹, 张勇¹, 胡小林², 陈才³, 谢文举¹

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室 重庆 400074;
2. 重庆工业大数据创新中心有限公司 重庆 400056; 3. 重庆华数机器人有限公司 重庆 400714)

摘要:目前工业机器人谐波减速器健康状态识别多以振动信号为载体,需要外加测试系统,增加了数据获取难度及成本,且其准确性和有效性受传感器安装位置影响。基于此,提出基于电压信号深度特征学习的谐波减速器健康状态识别方法。利用工业机器人电机电压信号对谐波减速器健康状态进行表征,使用连续小波变换将电压信号转换成时频图以获得谐波减速器不同健康状态下电压信号的时频信息,构建出数据样本集。利用卷积神经网络对电压信号时频信息进行自学习,并有监督调整网络参数,在获得谐波减速器不同健康状态下电压信号深度特征的同时实现对其健康状态的识别。实验结果显示,所提方法识别准确率达到90%以上,证明了该方法能够有效识别谐波减速器健康状态,并具有较好的泛化能力和稳健性。

关键词: 健康状态识别;谐波减速器;电压信号;卷积神经网络;连续小波变换

中图分类号: TH165+.3 TP18 **文献标识码:** A **国家标准学科分类代码:** 510.40

Health state recognition of harmonic reducer based on depth feature learning of voltage signal

Chen Renxiang¹, Zhang Yong¹, Hu Xiaolin², Chen Cai³, Xie Wenju¹

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Innovation Center of Industrial Big-Data Co., Ltd., Chongqing 400056, China; 3. CQHS Roboter Corporation, Chongqing 400714, China)

Abstract: At present, the health state recognition of industrial robot harmonic reducer is mainly based on vibration signals, which requires additional test system, increases the difficulty and cost of data acquisition, and its accuracy and effectiveness are affected by the installation location of sensors. Based on this, the health state recognition method of harmonic reducer based on depth feature learning of voltage signal is proposed. The industrial robot motor voltage signal is used to characterize the health state of harmonic reducer, and the continuous wavelet transform is used to transform the voltage signal into time-frequency diagram to obtain the time-frequency information of voltage signal under different health state of harmonic reducer, and the data sample set is constructed. The convolutional neural network is used to self-learn the time-frequency information of the voltage signal, and the network parameters are supervised to adjust. In this way, the health state of harmonic reducer can be recognized while the depth characteristics of voltage signal under different health state of harmonic reducer are obtained. Experiment results show that the recognition accuracy of the proposed method reaches 90% above, which proves that the proposed method can effectively recognize the health state of harmonic reducer, and has good generalization ability and robustness.

Keywords: health state recognition; harmonic reducer; voltage signal; convolutional neural network; continuous wavelet transform

收稿日期: 2021-03-13 Received Date: 2021-03-13

* 基金项目: 国家自然科学基金项目(51975079)、国家重点研发项目(2018YFB1306601)、重庆市教委科学技术研究项目(KJQN201900721)、重庆市研究生导师团队项目(JDDSTD2018006)、重庆市北碚区科学技术局技术创新与应用示范项目(2020-6)资助

0 引言

工业机器人工作稳定可靠、效率高,被广泛应用于制造业中。谐波减速器作为工业机器人关节的核心部件,其高精度运行保证了工业机器人的精准动作,对工业机器人稳定可靠地运行发挥至关重要的作用^[1]。谐波减速器的健康状态直接决定了工业机器人运行精度,对其进行健康状态识别十分必要^[2]。

近年来,国内外众多学者对谐波减速器等旋转机械健康状态识别与诊断方面开展了大量研究。陈仁祥等^[2]提出了基于整周期数据和卷积神经网络的谐波减速器健康状态评估方法,将谐波减速器振动信号分割构造整周期数据样本并分解获得时频图,最后通过卷积神经网络学习其瞬变特征并输出评估结果。于军等^[3]针对噪声干扰和时变转速工况下的行星齿轮箱故障识别率低的问题,提出了基于堆叠降噪自动编码器和门控循环单元神经网络的行星齿轮故障识别方法。Zhu等^[4]通过计算不同尺度下的模糊测度值以提取滚动轴承特征并进行降维,利用支持向量机实现故障诊断。Yu^[5]提出了一种基于粒子群算法和堆叠去噪自编码器的方法对齿轮箱进行故障诊断。

振动信号是机械设备的动力学响应,能够直接反映设备的运行特征,故以上方法均将振动信号作为运行状态信息刻画的载体。但是,对于工业机器人谐波减速器:1)需外加测试系统以获取振动信号,增加数据获取难度及成本,也不利于长期监测;2)工业机器人刚柔耦合、激励源众多、姿态变化快,谐波减速器及安装于其上的传感器会随机器人运动而运动,导致获取的振动信号干扰众多,且传感器安装位置也会影响振动信号对谐波减速器健康状态表征的准确性。

另一方面,工业机器人谐波减速器由电机驱动,其本质是由驱动电压输入到伺服关节转动再到柔性机械臂动作的过程^[6]。当谐波减速器健康状态发生改变(如卡顿、间隙过大)时,整个传动系统将产生额外的波动扭矩,电机将输出相应扭矩以平衡该额外扭矩,从而导致电机电压出现变化。因此,电压信号能反映出谐波减速器运行状态,同时,电压信号是工业机器人的实时信息,不必借助外部测试系统即可获取数据。所以,一个新的思路就是利用电压信号来表征谐波减速器健康状态。即,工业机器人电机呈现出“启动-加速-平稳-减速-停止-反向启动-加速-平稳-减速-停止”循环往复的工作特点,其电压信号则相应的呈现出“零-正向增大-平稳-减小-零-负向增大-平稳-负向减小-零”的周期性特点。当谐波减速器健康状态发生改变时,电压在周期性循环中势必出现差异,这种差异必然蕴含谐波减速器健康状态信息,如能提

取出这种信息就能实现对谐波减速器健康状态的表征和识别。

目前,卷积神经网络(convolutional neural network, CNN)因其局部连接、权值共享及池化操作等特性^[7],被广泛应用于故障预测与健康管理领域。如:Zhao等^[8]提出了一种基于归一化的CNN方法以解决数据不平衡和工况变化条件下的滚动轴承故障诊断问题;Liang等^[9]提出了一种基于小波变换、生成对抗网络和CNN的旋转机械故障检测方法;胡芑庆等^[10]将信号经过经验模态分解后的内禀模式函数作为CNN输入以对行星齿轮箱进行故障识别;咎涛等^[11]提出了一种方法多输入层卷积神经网络的滚动轴承故障诊断方法;刘涵等^[12]提出了基于X射线图像和卷积神经网络的石油钢管焊缝缺陷检测方法。由于CNN在时间和空间上对输入信号的平移、缩放具有高度不变性的特点,能自动学习样本特征,利用其对电压信号进行学习,提取电压信号深度特征以对谐波减速器健康状态进行表征和识别。

欲利用CNN提取电压信号中蕴含的健康状态特征,需将电压信号的二维时频信息进行充分展现。而连续小波变换(continuous wavelet transform, CWT)具有多分辨率的特点,能有效充分展示上述周期性电压信号的时频特征。因此,提出了基于电压信号深度特征学习的谐波减速器健康状态识别方法。即应用CWT对电压信号进行分解获得时频图,再利用CNN在时间和空间上对输入信号的平移、缩放具有高度不变性的特点,充分学习电压信号时频深度特征,从而实现谐波减速器健康状态识别。最后,通过实验验证所提方法的可行性和有效性。

1 理论基础

1.1 连续小波变换的原理

对于任意时域信号 $y(t) \in L^2(R)$,其连续小波变换表达式为^[13]:

$$S_y = \int_{-\infty}^{\infty} y(t) \overline{g_{m,n}(t)} dt \quad (1)$$

式中: $g_{m,n}(t)$ 是由母小波 $g(t)$ 经过尺度伸缩和平移得到的^[14]。

$$g_{m,n}(t) = \frac{1}{\sqrt{|m|}} g\left(\frac{t-n}{m}\right) \quad (2)$$

式中: m 为尺度因子; n 为平移因子,且 $\|g_{m,n}\|_2 = \|g\|_2$,同时 $g_{m,n}(t)$ 应满足如下约束条件:

$$\int_{-\infty}^{\infty} |g(t)| dt < \infty \quad (3)$$

连续小波逆变换表达式为:

$$y(t) = \frac{1}{D_g} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{m^2} S_y g\left(\frac{t-n}{m}\right) dm dn \quad (4)$$

其中,

$$D_g = \int_{-\infty}^{\infty} \frac{|G(\omega)|^2}{|\omega|} d\omega \quad (5)$$

式中: $G(\omega)$ 为母小波 $g(t)$ 的傅里叶变换。

1.2 卷积神经网络

CNN 是一种深度神经网络,具有局部感知、权重共享和多卷积核的特点,主要由输入层、卷积层、池化层、全连接层以及输出层组成^[15],如图1所示。输入的二维信号经过交替出现的卷积层及池化层提取特征后,最终通过分类器分类输出。




图1 卷积神经网络结构

Fig. 1 The structure of CNN

1) 卷积层

卷积层由多个卷积核构成,每个卷积核与输入信号进行卷积运算,然后经过激活函数得到特征图。激活函数为 sigmoid 函数,其函数表达式为:

$$h(x) = \frac{1}{1 + e^{-x}} \quad (6)$$

卷积过程数学表达式为:

$$Y_j^l = h\left(\sum_{i \in K_j} Y_i^{l-1} \cdot \omega_{ij}^l + b_j^l\right) \quad (7)$$

式中: Y_j^l 为第 l 层第 j 个元素; $h(\cdot)$ 为激活函数; K_j 为 $l-1$ 层特征图的第 j 个卷积区域; Y_i^{l-1} 为其中的元素; ω_{ij}^l 为对应卷积核的权重矩阵; b_j^l 为偏置项。

2) 池化层

池化层通常位于卷积层之后,对卷积层得到的特征图进行降维,并保证了特征尺度的不变性。常用的池化方式有均值池化、最大值池化和随机池化。

3) 全连接层

在全连接层,将卷积层和池化层得到的特征图展开为一列构成特征向量,特征向量与输出层全连接。选用的是 softmax 分类器,表达式为:

$$K_i = \frac{e^{L_i}}{\sum e^{L_i}} \quad (8)$$

式中: L_i 是数组 L 的第 i 个元素。

2 基于电压信号深度特征学习的谐波减速器健康状态识别流程

所提出的基于电压信号深度特征学习的谐波减速器健康状态识别方法原理如下:首先运用 CWT 对谐波减速器电压信号进行分解获得时频图以充分展现谐波减速器的时频特征;然后利用 CNN 在时间和空间上对输入信号的平移、缩放具有高度不变性的特点对电压信号时频信息进行学习,并有监督调整网络参数,在获得谐波减速器不同健康状态下电压信号深度特征的同时实现对其健康状态的识别。具体步骤如下。

1) 将谐波减速器电压信号进行连续小波变换以获得时频表达,需要注意,进行连续小波变换的电压信号至少要包括一个工作周期,这样才能得到谐波减速器一个工作周期以上的时频信息;

2) 划分训练样本与测试样本;

3) 设置网络参数,构建 CNN 模型;

4) 以批量方式输入训练样本到 CNN 中,依次经过卷积层、池化层、全连接层处理,得到输出;

5) 计算网络输出结果与预期目标间的误差,误差反向传播更新权重和偏置;

6) 重复步骤4)、5),直至将训练样本全部训练完毕且达到了迭代次数,得到训练好的 CNN 网络;

7) 将测试样本输入到已训练完毕的 CNN 模型中从而得到谐波减速器健康状态识别结果。

3 实验验证

3.1 实验数据

以型号 LHSG-17-80 谐波减速器为实验对象。对比电压信号与振动信号各自优势,实验过程中同时采集这两种信号(电压信号直接从工业机器人控制系统读出)。实验时,谐波减速器所在的末端关节上下往复运动。共使用3个振动传感器如图2所示。谐波减速器有3种状态:间隙过大、卡顿和正常。在工作节拍为60%满转速和100%满转速的下重复采集多组数据,每种状态样本数为170。分别从3种不同健康状态下的谐波减速器样本中随机选取130个样本构成训练样本,余下样本为测试样本,如表1所示。

图3为谐波减速器3种不同健康状态的电压信号时域波形图,图3(c)中电压信号明显呈现出“零-正向增大-平稳-减小-零-负向增大-平稳-负向减小-零”的周期性。根据该图,仅通过电压信号时域波形很难判断谐波减速器的健康状态。图4为3种不同健康状态的谐波减速器频谱和概率密度曲线对比,观察该图,不同




图2 传感器布置图

Fig. 2 Sensor layout

表1 谐波减速器样本集

Table 1 Sample set of harmonic reducer

状态类型	训练样本	测试样本	标签类别
间隙过大	130	40	I
卡顿	130	40	II
正常	130	40	III
合计	390	120	




图3 不同状态下的时域信号

Fig. 3 The time domain signals for different states




图4 频谱(左)和概率密度(右)对比

Fig. 4 The comparison of spectrum (left) and probability density (right)

健康状态下频谱(如主频及其幅值)和概率密度图均有明显差异,即说明电压信号能有效反映谐波减速器的健康状态。

图5为CWT时频图。观察该图,3种状态的谐波减速器能量主要集中在低频段。间隙过大和卡顿的谐波减速器能量几乎连续分布于0~3 Hz;而正常状态的谐波减速器能量在频段上是非连续的,主要集中在0~1.5 Hz和2.5 Hz;同时卡顿和正常状态的能量明显高于间隙过大的减速器。由此可知,不同健康状态下信号在连续小波时频图中表现出的差别明显比时域和频域所表现的差别更加突出,通过时频图更能展现谐波减速器不同健康状态下电压信号差异。




图5 连续小波变换时频图

Fig. 5 Time-frequency diagrams of CWT

3.2 实验结果及分析

CNN网络共有2个卷积层:分别有12、24个卷积核,卷积核的大小皆为 5×5 ;降采样层的池化区域为 2×2 。采用最值池化的方式,学习率0.01,批量大小64,迭代次数 $k=150$ 。本文介绍的所有任务均在配置Intel(R) Core(TM) i5-5200 CPU @ 2.2 GHz, 8 GB上进行。

分别将所提方法、频谱+CNN、时间序列+CNN、3个振动传感器信号+CNN、文献[2](利用传感器1的信号)进行对比,以分析所提方法的可行性和有效性。图6为60%工作节拍下不同健康状态的分类准确率和分类损失的对比结果,表2为不同迭代次数下准确率及耗时(各方法达到稳定准确率时所消耗的时间)。

表2 不同方法准确率

Table 2 The accuracies of different methods

	分类准确率/%			耗时/min
	$k=40$	$k=70$	$k=110$	
所提方法	96.67	100.00	100.00	2.69
频谱+CNN	75.00	83.33	90.83	2.57
时间序列+CNN	36.67	34.17	55.83	2.12
传感器1	60.00	77.50	90.83	2.71
传感器2	39.17	40.83	70.00	2.80
传感器3	65.83	59.17	78.33	2.73
文献[2]	100.00	100.00	100.00	30.16




图6 准确率与分类损失对比

Fig. 6 The comparison of accuracy and classification loss

根据图6、表2,振动传感器1、2、3的准确率逐步提高,最高可达到90.83%,但由于安装位置不同,准确率差异大(如传感器2在 $k=110$ 时仅为70%)。文献[2]可以得到100%的准确率,且其分类损失和准确率虽迭代次数收敛最快,原因在于其将传感器1的信号进行整周期截取建立样本,更准确刻画了谐波减速器运行状态。但是,这种方法由于要进行整周期截取,且数据量远大于电压信号,每次迭代耗时大,故其耗时最多(30.82 min),是所提方法的11倍。

时间序列+CNN方法识别效果明显不佳,虽然随着迭代次数的增加,分类损失有所下降,分类准确率也在缓慢提高,但最终分类准确率也仅为73.33%,原因在于时间序列只反映了时域特性,对谐波减速器健康状态信息展现不足,不利于CNN学习提取特征。

频谱+CNN方法的分类损失随着迭代次数的增加也呈现了不断降低的趋势,在迭代次数 $k=140$ 时,分类损失接近0。分类准确率逐步上升,在 $k=110$ 时达到90.83%。原因在于频谱只反映了频域特性,不能全面刻画谐波减速器的时频信息,识别效果也不佳。

所提方法随着迭代次数的增加,分类损失迅速降低直至0,分类准确率不断提高。当迭代次数 $k=40$ 时,分类准确率已达到了96.67%;当 $k=70$ 时,分类准确率达到100%。说明所提方法是可行、有效的。

综上所述,所提方法与文献[2]的方法准确率最终都能达到100%,明显高于其他方法。但是,文献[2]的方法一方面运用振动信号以表征谐波减速器的运行状态,需要外加测试系统,不利于工程应用;另一方面由于其样本数据庞大,同时需要进行整周期数据截取,耗时更多。而所提方法充分利用工业机器人驱动电机本身的电压信号,所耗计算资源更少,能够大幅度降低进行健康状态识别的配置要求,同时由于无需借助外部测试系统,有效减少了进行健康管理的成本,并且提高了进行状态监测的效率,更利于实际工程实践。

为进一步分析CNN不同的网络层数对识别结果的影响,设计3种不同卷积层个数的CNN网络结构,分别包含2层卷积层、3层卷积层CNN及4层卷积层,利用表1所述样本集分别对其进行训练、测试,结果如表3所示。表中, N_{c1} 、 N_{c2} 、 N_{c3} 、 N_{c4} 分别表示CNN第1、2、3、4层卷积层的卷积核个数, k 表示和耗时分别为准确率达到稳定时的迭代次数和耗时。

表3 网络结构对比结果

Table 3 Comparison result of network structure

卷积层 层数	网络结构参数				分类 准确率/%	k	耗时/s
	N_{c1}	N_{c2}	N_{c3}	N_{c4}			
2	12	24	—	—	100	40	4
3	12	24	24	—	100	76	20
4	12	24	24	36	100	83	31

根据表3,虽然2、3、4层卷积层的CNN均能达到100%的准确率,但是3、4层卷积层的CNN的效率远低于2层卷积层的CNN,所需迭代次数分别为76、83次,耗时分别为20、31 s;而2层卷积层的CNN所需迭代次数仅为40,耗时也仅为4 s。由此可知,CNN卷积层个数的增加会增加网络计算量,使得耗时更多,从而导致识别效率更低。

为进一步验证所提方法的有效性,在100%满转速的工作节拍下重复试验。样本集设置如表4所示。图7、表5为谐波减速器在100%满转速的工作节拍下不同健康状态的分类准确率,表中耗时表示各方法达到稳定准确率时所消耗的时间。

根据图7、表5,在100%满转速的工作节拍下,所提方法依然具有较好的识别结果。与此同时,频谱+CNN和时间序列+CNN方法、传感器1、2、3等方法虽随着迭代次数的增加分类准确率也有缓慢地提高,

表 4 谐波减速器样本集

Table 4 Sample set of harmonic reducer

状态类型	训练样本	测试样本	标签类别
间隙过大	120	30	I
卡顿	120	30	II
正常	120	30	III
合计	360	90	




图 7 不同方法分类准确率

Fig. 7 Classification accuracies of different methods

表 5 不同方法准确率

Table 5 The accuracies of different methods

	分类准确率/%			耗时/min
	$k=40$	$k=70$	$k=110$	
所提方法	94.44	100.00	100.00	2.52
频谱+CNN	33.33	33.33	67.78	2.61
时间序列+CNN	33.33	37.78	44.44	2.10
传感器 1	57.78	73.33	94.44	2.75
传感器 2	50.00	62.22	72.22	2.73
传感器 3	65.56	82.22	96.67	2.69
文献[2]	100.00	100.00	100.00	31.01

但是最终精度远差于所提方法。相较于文献[2],所提方法依然具有更短的耗时(文献[2]的耗时约为所提方法的 11 倍)。进一步说明了所提方法的可行性、有效性及其优势。

为进一步验证所提方法的泛化能力和稳健性,在混合工作节拍下对谐波减速器进行健康状态识别,即训练样本和测试样本的工作节拍均包含 60% 满转速和 100% 满转速。训练样本与测试样本如表 6 所示。

表 6 混合工作节拍样本集设置

Table 6 Sample set setting of mixed working beats

状态类型	训练样本		测试样本	
	节拍	样本数	节拍	样本数
间隙过大	60%/100%	280	60%/100%	60
卡顿	60%/100%	280	60%/100%	60
正常	60%/100%	280	60%/100%	60

表 7 为混合工作节拍下各方法的准确率及耗时对比,表中耗时表示各方法达到稳定准确率时所消耗的时间。观察表 7 在 60% 满转速和 100% 满转速的混合工作节拍下,所提方法依然具有较好的识别结果。在迭代次数 $k=150$ 时,分类准确率达到 94.44%。与此同时,频谱+CNN 和时间序列+CNN 方法、传感器 1、2、3 等方法虽随着迭代次数的增加分类准确率也有缓慢地提高,但是最终精度远差于所提方法。相较于文献[2],所提方法依然具有更短的耗时。由此可知,对于混合工作节拍下的谐波减速器健康状态识别,所提方法依然具有较好的分类效果,证明了其具有较好的泛化能力和稳健性。

表 7 不同方法准确率

Table 7 The accuracies of different methods

	分类准确率/%			耗时/min
	$k=40$	$k=110$	$k=150$	
所提方法	60.56	62.22	94.44	5.52
频谱+CNN	38.89	66.67	68.33	5.27
时间序列+CNN	35.56	31.11	46.11	4.33
传感器 1	47.78	81.67	90.56	5.29
传感器 2	49.44	65.56	68.33	5.31
传感器 3	69.44	83.33	89.44	5.40
文献[2]	76.11	81.67	93.89	56.9

4 结 论

本文提出了基于电压信号深度特征的谐波减速器健康状态识别方法。利用工业机器人驱动电机本身的电压信号对谐波减速器健康状态进行表征,通过卷积神经网络学习提取电压信号深度特征实现了对谐波减速器健康状态的识别。避免了振动信号需要外加测试系统、增加成本、不利于长期监测和选定测点等问题,且所提方法充分利用工业机器人驱动电机本身的电压信号,所耗计算资源更少,能够大幅度降低进行健康状态识别的配置要求,同时由于无需借助外部测试系统,有效减少了进行健

康管理的成本,并且提高了进行状态监测的效率,更利于实际工程实践。60%和100%满转速工况以及混合工作节拍的实验证明了所提方法的可行性、有效性和优势。为工业机器人谐波减速器的健康状态识别与智能运维提供了新的思路与方法。

参考文献

- [1] 王田苗,陶永.我国工业机器人技术现状与产业化发展战略[J].机械工程学报,2014,50(9):1-13.
WANG T M, TAO Y. Current situation and industrialization development strategy of industrial robotics in China [J]. Journal of Mechanical Engineering, 2014, 50(9):1-13.
- [2] 陈仁祥,张勇,杨黎霞,等.基于整周期数据和卷积神经网络的谐波减速器健康状态评估[J].仪器仪表学报,2020,41(2):245-252.
CHEN R X, ZHANG Y, YANG L X, et al. Health status assessment of harmonic reducer based on integer-period data and convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(2):245-252.
- [3] 于军,高莲莲,于广滨,等.基于SDAE和GRUNN的行星齿轮故障识别[J].振动与冲击,2021,40(2):156-163.
YU J, GAO L L, YU G B, et al. Fault identification of planetary gear based on SDAE and GRUNN [J]. Journal of Vibration and Shock, 2021, 40(2):156-163.
- [4] ZHU K H, CHEN L, HU X. A multi-scale fuzzy measure entropy and infinite feature selection based approach for rolling bearing fault diagnosis [J]. Journal of Nondestructive Evaluation, 2019, 38(4):1-13.
- [5] YU J B. Evolutionary manifold regularized stacked denoising autoencoders for gearbox fault diagnosis [J]. Knowledge-Based Systems, 2019, 178:111-122.
- [6] 周优鹏,娄军强,陈特欢,等.伺服关节驱动的柔性臂系统耦合动力学模型辨识与实验[J].振动与冲击,2019,38(9):277-284.
ZHOU Y P, LOU J Q, CHEN T H, et al. Identification and experiment of coupling dynamics model of servo joint driven flexible arm system [J]. Journal of Vibration and Shock, 2019, 38(9):277-284.
- [7] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6):1229-1251.
ZHOU F Y, JIN L P, DONG J. Overview of convolutional neural networks [J]. Chinese Journal of Computers, 2017, 40(6):1229-1251.
- [8] ZHAO B, ZHANG X M, LI H, et al. Intelligent fault diagnosis of rolling bearings based on normalized CNN considering data imbalance and variable working conditions [J]. Knowledge-Based Systems, 2020, DOI: 10.1016/j.knsys.2020.105971.
- [9] LIANG P F, DENG C, WU J, et al. Intelligent fault diagnosis of rotating machinery via wavelet transform, generative adversarial nets and convolutional neural network [J]. Measurement, 2020, DOI: 10.1016/j.measurement.2020.107768.
- [10] 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 N Q, CHEN H P, CHENG ZH, et al. Fault diagnosis method of planetary gear box based on empirical mode decomposition and deep convolutional neural network [J]. Journal of Mechanical Engineering, 2019, 55(7):9-18.
- [11] 咎涛,王辉,刘智豪,等.基于多输入层卷积神经网络的滚动轴承故障诊断模型[J].振动与冲击,2020,39(12):142-149,163.
ZAN T, WANG H, LIU ZH H, et al. Rolling bearing fault diagnosis model based on multi-input layer convolutional neural network [J]. Journal of Vibration and Shock, 2020, 39(12):142-149,163.
- [12] 刘涵,郭润元.基于X射线图像和卷积神经网络的石油钢管焊缝缺陷检测与识别[J].仪器仪表学报,2018,39(4):247-256.
LIU H, GUO R Y. Detection and identification of weld defects in petroleum steel pipe based on X-ray image and convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(4):247-256.
- [13] 李宏坤,刘洪轶,徐福健,等.连续小波最优重构尺度确定方法与故障早期识别[J].机械工程学报,2014,50(17):69-76.
LI H K, LIU H Y, XU F J, et al. Determination method of optimal reconstruction scale of continuous wavelet and early fault identification [J]. Journal of Mechanical Engineering, 2014, 50(17):69-76.
- [14] 李宏坤,练晓婷,周帅.小波尺度谱同步平均在弱信息识别中的应用[J].机械工程学报,2013,49(5):32-38.

LI H K, LIAN X T, ZHOU SH. Application of wavelet scale spectrum synchronization average in weak information recognition [J]. Journal of Mechanical Engineering, 2013, 49(5):32-38.

- [15] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法 [J]. 振动与冲击, 2018, 37(19):132-139.

LI H, ZHANG Q, QIN X R, et al. Fault diagnosis method of bearing based on short-time Fourier transform and convolutional neural network [J]. Journal of Vibration and Shock, 2018, 37(19):132-139.

作者简介



陈仁祥, 分别在 2007 年和 2012 年于重庆大学获得学士学位和博士学位, 现为重庆交通大学教授、博士生导师, 主要研究方向为智能测试技术与信号处理。

E-mail: manlou.yue@126.com

Chen Renxiang received his B.Sc. and Ph.D. degrees both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and doctoral supervisor at Chongqing Jiaotong University. His main research interests include


intelligent testing technology and signal processing.



张勇, 2018 年于太原科技大学获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为机电装备故障诊断及安全服役。

E-mail: 248692294@qq.com

Zhang Yong received his B.Sc. degree from Taiyuan University of Science and Technology in 2018. He is currently a M.Sc. student at Chongqing Jiaotong University. His main research interests include fault diagnosis and safety service of electromechanical equipment.



胡小林 (通信作者), 2010 年于重庆大学获得硕士学位, 现为重庆工业大数据创新中心有限公司高级工程师, 主要研究方向为机电装备故障诊断及安全服役。

E-mail: huxl0918@163.com

Hu Xiaolin (Corresponding author) received the M.Sc. degrees from Chongqing university, Chongqing, China, in 2010. He is currently a senior engineer at Chongqing Innovation Center of Industrial Big-Data Co. Ltd, Chongqing, China. His main research interests industrial big data mining and fault diagnosis.