DOI: 10. 19650/j.cnki.cjsi.J1905063

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^{*}

孔子迁,邓 蕾,汤宝平,韩 延

(重庆大学机械传动国家重点实验室 重庆 400044)

摘 要:针对行星齿轮箱振动信号频率成分复杂和时变性强的问题,提出了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。首先,采用小波包分解将原始振动信号分解到频带和时间两个维度作为输入数据;然后,使用卷积神经网络融 合数据的频带特征,使用双向门控循环单元融合时序特征;接着采用注意力结构对不同时间点的特征自适应地进行动态加权融 合;最后通过分类器进行识别,实现行星齿轮箱的端对端故障诊断。实验表明,该方法对比现有的深度学习故障诊断模型具有 更高准确率,能够对行星齿轮箱多种健康状态进行准确地诊断。

关键词:行星齿轮箱;故障诊断;时频融合;注意力机制

中图分类号: TH17 文献标识码: A 国家标准学科分类代码: 510.40

Fault diagnosis of planetary gearbox based on deep learning with time-frequency fusion and attention mechanism

Kong Ziqian, Deng Lei, Tang Baoping, Han Yan

(State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400044, China)

Abstract: The vibration signal of planetary gearbox has the complexity of frequency component and time-varying. To solve this problem, the fault diagnosis method based on deep learning with time-frequency fusion and attention mechanism is proposed. Firstly, the wavelet packet decomposition is used to transform the original vibration signal into two dimensions of frequency band and time, which are adopted as input data. Then, the convolutional neural network is applied to fuse the frequency band characteristics of the data. The bidirectional gated recurrent unit is employed to fuse the timing features. The attention structure is adopted to weight and merge the features of different time point adaptively and dynamically. Finally, the classifier is used to identify the end-to-end fault diagnosis of the planetary gearbox. Experimental results show that this method has higher accuracy than the existing deep learning fault diagnosis model. It can accurately diagnose various health states of planetary gearbox.

Keywords: planetary gearbox; fault diagnosis; time-frequency fusion; attention mechanism

0 引 言

行星齿轮箱作为机械传动系统的重要部件,广泛应 用于风力发电机组、直升机主减速器等重大装备中。由 于其在实际运行中常受到工况交变的影响,容易导致太 阳轮、行星轮、齿圈、轴承等关键部件发生故障^[1]。因此, 研究行星齿轮箱的故障诊断方法具有重要意义。 近年来,随着人工智能技术的迅速发展,深度学习方 法在行星齿轮箱故障诊断领域已经开展了一些研究^[2]。 其中,部分学者直接利用深度学习模型对时域或频域信 号进行特征提取和故障诊断。Han Y 等^[3]使用了增大感 知视野的一维卷积与二维卷积联合的深度神经网络,对 时域振动信号进行特征提取和故障分类;金棋等^[4]采用 多个堆栈去噪自动编码器,从行星齿轮箱振动信号的频 谱中提取多样性特征,进行故障诊断。然而单一维度的

收稿日期:2019-04-28 Received Date:2019-04-28

^{*}基金项目:国家自然科学基金(51775065,51675067)项目资助

信息难以全面表征信号中包含的信息,为了获取多维度 的信息,部分学者使用时频分析方法对振动信号进行初 步特征提取。胡茑庆等^[5]将行星齿轮箱振动信号通过经 验模态分解,然后输入到深度卷积神经网络进行故障的 分类识别;Zhao等^[6]对振动信号进行小波包分解,构建 二维时频图样本,再输入到以卷积层为基础的深度残差 网络进行故障诊断。然而,上述方法都仅是使用单一的 网络结构,特征提取能力有限,无法充分发掘蕴含的时频 信息,精度难以保证^[7]。

在行星齿轮箱中,行星轮在自传同时还绕太阳轮公转,多对齿轮同时啮合,还包含多个轴承的振动,频率成分复杂;同时由于工况波动,导致振动信号具有很强的时变性,不同时间内的信号特征具有很大差异^[8-9]。因此,针对行星齿轮箱振动信号频率信息复杂、时变性强的特点,本文提出了一种基于齿轮箱振动信号时频融合和注意力机制的深度学习故障诊断方法。使用卷积神经网络(convolutional neural network, CNN)和具有时间延展性的双向门 控循环单元(bidirectional gated recurrent unit, BiGRU)融合时频信息,通过注意力机制模块对时间维度上不同时间点的特征进行动态加权,以更加准确地对行星齿轮箱进行故障诊断。

基于时频融合和注意力机制的深度学习 模型设计

基于时频融合和注意力机制的深度学习故障诊断方 法依赖于模型的设计。本节针行星齿轮箱振动信号中频 率信息复杂、时变性强的特点设计了以卷积神经网络与 双向门控循环单元融合时频信息,注意力结构对变化的 时间特征动态加权的深度学习模型,实现行星齿轮箱的 故障诊断。

本文设计的深度学习模型采用小波包系数矩阵作为 输入,通过小波包分解方法将原始振动信号分解到时域 和频域两个维度。对于行星齿轮箱振动信号这种非平稳 信号,小波包分解能够有效表征其不同频带和不同时间 内的能量信息,可以反映其在短时间内各个频带信息的 快速变化。小波包分解过程如图1所示,将原始信号分 解后得到的二维小波包系数矩阵作为深度学习模型的 输入^[6]。

1.1 频带特征融合

由于行星齿轮箱中包含多个振动频率,在其振动信号的小波包分解系数矩阵中,各个频带内的幅值反映了 不同结构的运行状态,且不同频带之间的关联信息可以 揭示深层次的健康状况。因此,需要对信号中的频带特 征进行提取和融合,对其进行综合利用,解决频率成分复 杂的问题。





CNN 是一种具有局部感知能力的神经网络结构,通 过局部连接的网络节点组成卷积核来扫描输入数据,提 取数据的细节特征,因其强大的特征学习能力被广泛应 用于图像识别等领域。CNN 计算过程可表示为:

$$x_{j}^{l} = f\Big(\sum_{i} x_{i}^{l-1} * k_{ij}^{l} + b_{j}^{l}\Big)$$
(1)

式中: x_i^l 为第l层输出的第j个特征图; x_i^{l-1} 为第(l-1)层 的第i个特征图; k_{ij}^l 为第i个输入特征图与第j个特征图连 接的卷积核; b_j^l 为偏置项; * 为卷积操作; $f(\cdot)$ 激活函 数。本文采用整流线性单元(rectified linear unit, ReLU),其函数表达如下:

$$f(x) = \max\{0, x\} \tag{2}$$

本文采用一维 CNN 来融合行星齿轮箱振动信号小 波包特征矩阵在频域维度的特征,过程如图 2 所示。通 过多个一维卷积核,信号在不同频带的特征信息会被融 合为新的特征。因此,模型可以自适应地学习行星齿轮 箱振动信号中的复杂频率信息,并将原始频率信息重组 为新的特征。由于一维卷积核会沿着小波包特征矩阵时 间轴的方向进行扫描,所以输出数据中依然包含了时间 维度的特征^[10-11]。



图 2 频带特征融合示意 Fig.2 The illustration of band feature fusion

1.2 时序特征融合

在振动信号中,除不同频带之间的关联特征外,各个 频带的幅值随时间变化的特征同样反映行星齿轮箱的健 康状况。然而 CNN 主要适用于提取信号的局部特征,难 以感知长序列中的整体变化特征^[12-13]。对于行星齿轮箱 振动信号,需要融合时间维度的特征来增强对其健康状 态的识别能力。

门控循环单元(gated recurrent unit, GRU)是一种改进的循环神经网络,被专门用于处理时间序列数据,能够保存序列的前后变化特征,因此可以用于融合数据在时间维度的特征。其单元内部结构如图3所示。



Fig.3 The structure of GRU cell

其计算过程可表示为:

$$z_t = \sigma_g(W_z x_t + U_z h_{t-1} + b_z)$$
(3)

$$r_{t} = \sigma_{g}(W_{r}x_{t} + U_{r}h_{t-1} + b_{r})$$
(4)

$$\tilde{h}_{t} = \sigma_{h}(W_{h}x_{t} + U_{t}(r_{t} \otimes h_{t-1}) + b_{h})$$
(5)

 $h_{t} = (1 - z_{t}) \otimes h_{t-1} + z_{t} \otimes \tilde{h}_{t}$ $\tag{6}$

式中: $W \in \mathbf{R}^{d\times k}$, $V \in \mathbf{R}^{d\times d}$, $b \in \mathbf{R}^{d}$ 为可训练参数; \otimes 为叉 积运算; x_{i} 和 h_{i} 分别为输入和输出向量; z_{i} 和 r_{i} 分别为更 新和重置门向量; σ_{g} 和 σ_{h} 为激活函数。本文分别采用 Hard Sigmoid 和 Tanh 作为激活函数。Hard Sigmoid 函数 表达如下:

$$f(x) = \begin{cases} 0, & x < -2.5\\ 0.2x + 0.5, & -2.5 \le x \le 2.5\\ 1, & x > 2.5 \end{cases}$$
(7)

Tanh 函数表达如下:

$$f(x) = \frac{e^{x} - e^{-x}}{e^{x} + e^{-x}}$$
(8)

GRU 单元每次接收一组时刻的数据,并将上一时刻的状态反馈回来,与当前的数据合并作为输入,计算输出后再循环进行下一次计算,直到最后一个时间刻度为止,从而获取输入数据在时间维度上的整体变化特征。相比于标准 RNN 结构,GRU 通过控制更新门与重置门的状态来选择性学习和遗忘时间序列中的特征,从而具有长期记忆的能力。为了进一步增强模型的时间特征融合能力,本文采用了双向的 BiGRU 结构,其时序展开如图 4 所示。从图 4 中可以看出,BiGRU 通过一次正向扫描可得到当前时间之前的时间序列特征,通过一次逆向扫描

可得到当前时间之后的时间序列特征。相比于单向 GRU,可以大大提高特征融合的效率。



Fig.4 The expansion view of bidirectional GRU layer

1.3 基于注意力机制的动态加权融合

行星齿轮箱由于工况交变的影响,其振动信号具有 很强的时变性。因此在不同时间内采集的信号具有不同 的特征,不同样本之间的差异较大,会大大降低深度学习 模型的泛化能力。

深度学习中的注意力机制(attention mechanism)^[4] 是一种仿生概念,模拟人类对于观察对象内容的特定部 分进行重点关注的过程,通过将注意力聚焦到对象信息 的不同位置来提升信息获取的能力。本文在深度学习模 型中加入注意力机制,对 BiGRU 层在不同时刻输出的特 征进行动态加权融合,使得模型可以在面对时序特征有 明显差异的信号时,自适应地将"注意力"聚焦在不同的 时刻,解决振动信号时变性引起的样本差异问题。

本文设计的注意力结构构造方式如下:

$$e_t = f\left(\sum W_t^i h_t^i + b_t^i\right) \tag{9}$$

$$\alpha_t = \frac{\exp(e_t)}{\sum\limits_{k=1}^{T} \exp(e_k)}$$
(10)

 $s_t = \alpha_t h_t$ (11) 式中: $f(\cdot)$ 为激活函数; BiGRU 的隐藏状态序列 h_t 被输 入到全连接层,从而产生动态权值 α_t ; s_t 为动态加权融合 后的特征向量。

注意力机制结构如图 5 所示,从图中可以看出,神经 网络通过学习输入数据自身的信息,对每一个时刻的特 征都输出一个权值 α,,代表网络的"注意力",权值的大 小表示注意力的聚焦程度。由于行星齿轮箱振动信号不 同样本在不同时刻表现出的特征有很大差异,注意力机 制可以帮助神经网络动态地对不同时刻的特征赋予权 值,因此可以更有效地提升有用信息的利用程度,降低模 型对输入数据的敏感性。

2 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流程

基于时频融合和注意力机制的深度学习行星齿轮箱



故障诊断分为4个步骤:信号采集与截断、样本的小波包 分解、深度学习模型的设计与训练、故障诊断测试。

1)信号采集与截断:采用振动传感器来采集行星齿 轮箱的振动信号,将获取的信号进行等长度截断得到 样本; 2)样本的小波包分解:将一维振动样本信号进行小 波包分解,得到二维时频图样本,并将其划分为训练集和 测试集;

3) 深度学习模型的设计与训练:构建图 6 中所示的 模型,使用训练集数据进行模型参数的训练,并在训练过 程中不断调整超参数,达到较好的性能;

4)故障诊断测试:模型训练完成之后,使用训练集数 据进行故障诊断测试,验证模型的诊断性能。

按照上文所述方法构建深度学习模型,其结构如图 6所示。其中,批归一化是对卷积层的输出数据进行归 一化,能够使神经元的激活程度趋向于正态分布,避免过 度饱和,从而一定程度上缓解梯度消失的问题,可以加快 收敛速度和提高模型准确率。



图 6 基于时频融合和注意力机制的深度学习模型结构

Fig.6 The framework of deep learning model of time-frequency fusion and attention mechanism

全局平均池化被用于压缩融合特征数据的维度,能 够保留显著特征,并有效降低网络参数的数量,降低网络 的复杂程度,防止过拟合。本文在时频融合与注意力结 构融合之后采用了全局平均池化操作,可以对已融合的 特征进行统计和降维,便于后续的分类识别。

Dropout 是一种有效减轻过拟合的方法。其过程是 在每一次训练更新网络参数时,随机地丢弃一部分权重, 仅对保留下的权重进行反向传播进行更新。通过这种方 式,可以降低网络对某些神经元的过度依赖,减轻神经元 之间复杂的共适应关系,从而提升网络的泛化能力。本 文在全连接层之间设置了 Dropout 操作,其仅在训练过程 中生效,在测试过程中不生效。

深度学习模型输出的最终结果通过 Softmax 分类器 生成概率分布,对输入数据的故障种类进行判断。其数 学表示如下:

$$y_j = \frac{e^{x_j}}{\sum\limits_{i} e^{x_i}}$$
(12)

本文选择交叉熵作为损失函数来计算深度学习模型 的计算值与真实值之间的误差,推动其反向传播更新参数。该损失函数的表示如下:

表1 模型结构参数

Parameters of the model

Table 1 Tarameters of the model				
网络结构	结构参数	备注		
卷积层1 批归一化	卷积核 5×128	f(g): Relu		
卷积层 2 批归一化	卷积核 3×128	f(g): Relu		
BiGRU	节点数 128	σ_{g} : Hard Sigmoid σ_{h} : Tanh		
注意力结构	节点数 256			
全局平均池化				
全连接层	节点数 512	f(g): Relu		
Dropout	丢弃率 0.5			
全连接层	节点数9	f(g): Softmax		

$$L = -\sum_{j=1}^{N} t_j \log y_j \tag{13}$$

式中: N 为故障种类数; t_j 为真实的样本标签; y_j 为 Softmax 的输出估计值。

使用 RMSprop 优化算法作为模型训练的优化器,在反向传播的过程中不断迭代更新参数,使得模型的预测结果

更接近于真实值。RMSprop 能够限制反向传播过程中梯 度下降的振荡,使得网络能够获得更精确的计算结果。

3 实验及结果分析

3.1 实验过程

利用动力传动综合试验台为实验对象采集不同转速 工况下的多种故障振动信号,试验台结构如图7所示,由 两级行星齿轮和两级平行齿轮传动系统构成,齿轮箱参 数如表2所示。实验共模拟了行星齿轮箱的9种健康状态,包括完全正常状态、4种齿轮故障和4种轴承故障, 如表3所示。加速度传感器布置在第一级行星齿轮处, 型号为PCB352C03,信号采集器为NI9234采集卡,采样 频率为25 600 Hz。采集时间设置为48 s,通过速度控制 器改变电机转频,电机转速在采集时间内由1 200 rpm 均 匀加速至1 900 rpm。为了降低随机因素的影响,每组健 康状态数据重复采集4次。



图 7 动力传动综合试验台 Fig.7 Drivetrain dynamics simulator

	表 2	行星齿轮箱参数
Table 2	Paran	neters of planetary gearbox

行星齿轮 -	齿数		宫抽些秋	齿数	
	第一级	第二级	一	第一级	第二级
太阳轮	20	28	输入轴	100	_
内齿圈	100	100	中间轴	29	36
行星轮	40	36	输出轴	—	90

为了模拟真实的运行状况,在采集到的信号加入 5 db白噪声。信号的截取长度设置为 4 096,每种健康状态得到 1 200 份样本。采用 DB1 小波包函数进行六层小 波包分解,将每个样本分解构造成 64×64 的二维小波包 系数矩阵。从每种健康状况数据集中随机选取 1 000 份 作为训练样本,其余 200 份作为测试样本。深度学习模 型的学习率设置为 0.0005,训练迭代次数设置为 50 次。

表 3	实验中行星齿轮箱9种健康状态	
-----	----------------	--

 Table 3
 Nine kinds of health states of the planetary

gearbox in the experiment

类别编号	健康状态
1	正常状态
2	太阳轮齿根裂纹故障
3	太阳轮齿面点蚀故障
4	太阳轮断齿故障
5	太阳轮缺齿故障
6	行星轮滚动轴承滚动体故障
7	行星轮滚动轴承内圈故障
8	行星轮滚动轴承外圈故障
9	行星轮滚动轴承复合故障

3.2 实验结果及分析

为了验证本文提出的模型的性能,基于相同的数 据集情况下,与目前已提出的 AlexNet^[15]、 GoogLeNet^[16]、ResNet^[6]深度学习方法进行了对比。为 了降低偶然因素的影响,在划分训练集和测试集时,进 行 10 次随机划分,使用每一组数据进行独立训练和测 试,分别记录实验结果。将10次实验的结果作为对比 验证的性能评估指标,具体结果如图8所示,平均准确 率和标准差如表 4 所示。其中, AlexNet 模型准确率较 差,仅达到92.32%,原因是该模型简单地将多个卷积 层进行堆叠,难以有效提取复杂的数据特征。 GoogLeNet 模型在每一卷积层中增加了不同大小的卷 积核,具有一定的频率特征提取能力,准确率相比 AlexNet 提高了 1.34%。ResNet 在 GoogLeNet 基础上增 加了残差结构,实现各卷积层的跨层连接,其准确率比 GoogLeNet 提高 1.33%。但是由于以上模型都是用单 一的网络结构进行特征提取,都无法全面地利用信号 所包含的信息,因此整体准确率偏低。本文提出的方 法可以充分融合信号中的时频特征,并且嵌入注意力 机制进行动态加权,平均测试准确率达到 97.23%,并 且在每一次测试中,其准确率都明显高于其他深度学 习模型。以上结果表明,本文提出的基于时频融合和 注意力机制的深度学习行星齿轮箱故障诊断方法相比 于其他几种深度学习故障诊断方法具有明显优势。

表 4 实验结果 Table 4 Experimental results

		-		
准确率/%	本文方法	AlexNet	GoogLeNet	ResNet
训练	99.40±0.17	99.20±0.77	98.70±0.88	99.94±0.07
测试	97.23±0.53	92.32±1.23	93.66±0.22	94.93±0.19





为了进一步分析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对不同健康状态振动数据 的诊断能力,探究其各个隐藏层对数据的信息融合效果, 采用 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding,t-SNE)对数据进行降维并可视化。分别分析 了 CNN 层输出、BiGRU 层输出、注意力结构输出、最终诊 断输出数据在三维空间中的分布情况。从图 9 中可以看 出,随着网络融合特征不断增加,在数据依次通过频率特 征融合、时序特征融合、注意力结构时,不同类别的数据 样本类间距离不断增加,类内距离不断减小,在空间中的 分布边界逐渐清晰,可分性不断增加,最终在输出层可以 进行准确的故障诊断。因此,本文提出的基于时频融合 和注意力机制的深度学习方法可以有效融合振动信号中 的信息,对行星齿轮箱故障具有明显的诊断效果。





4 结 论

针对行星齿轮箱运行过程中频率成分复杂、时变性 强的问题,本文提出了一种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,实现了对行星齿 轮箱振动数据的智能故障诊断。

采用小波包分解,将原始振动信号分解到频带和时间两个维度,作为深度学习模型的输入。通过 CNN、 BiGRU 融合数据时频特征,并利用注意力结构对不同时间点的特征进行动态加权融合,解决信号强时变性的问题,进一步提高模型的故障诊断性能。实验对比结果表明本文提出的基于时频融合和注意力机制的深度学习方法有效提高了行星齿轮箱故障诊断的准确率。

参考文献

- [1] 雷亚国,何正嘉,林京,等.行星齿轮箱故障诊断技术的研究进展[J].机械工程学报,2011,47(19):59-67.
 LEIYG, HE ZHJ, LINJ, et al. Research advances of fault diagnosis technique for planetary gearboxes [J]. Chinese Journal of Mechanical Engineering, 2011,47(19):59-67.
- [2] 雷亚国,贾峰,周昕,等.基于深度学习理论的机械 装备大数据健康监测方法[J].机械工程学报,2015, 51(21):49-56.
 LEIYG, JIAF, ZHOUX, et al. A deep learning-based method for machinery health monitoring with big data[J]. Chinese Journal of Mechanical Engineering, 2015, 51(21):49-56.
- [3] HAN Y, TANG B, DENG L. An enhanced convolutional neural network with enlarged receptive fields for fault diagnosis of planetary gearboxes [J]. Computers in Industry, 2019, 107: 50-58.
- [4] 金棋,王友仁,王俊.基于深度学习多样性特征提取 与信息融合的行星齿轮箱故障诊断方法[J].中国机 械工程,2019,30(2):196-204.
 JIN Q, WANG Y R, WANG J, Planetary gearbox gault diagnosis basedon multiple feature extractionand information fusion combined with deep learning [J]. China Mechanical Engineering [J]. 2019, 30 (2): 196-204.
- [5] 胡茑庆,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/OL].机械 工程学报,2019,55(7):9-18[2019-04-23].http://kns. cnki.net/kcms/detail/11.2187.TH.20190124.1320.074. html.

HU N Q, CHEN H P, CHENG ZH, et al. Fault

diagnosis for planetary gearbox based on EMD and deep convolutional neural networks [J/OL]. Chinese Journal of Mechanical Engineering, 2019, 55 (7): 9-18 [2019-04-23]. http://kns. cnki. net/kcms/detail/11.2187. TH. 20190124.1320.074.html.

- [6] ZHAO M, KANG M, TANG B, et al. Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes [J]. IEEE Transactions on Industrial Electronics, 2018, 65(5): 4290-4300.
- SHAO H, JIANG H, WANG F, et al. An enhancement deep feature fusion method for rotating machinery fault diagnosis [J]. Knowledge-Based Systems, 2017, 119: 200-220.
- [8] 李东东,王浩,杨帆,等.基于无监督特征学习的行星 齿轮箱故障特征提取和检测[J].电网技术,2018, 42(11):3805-3811.

LI D D, WANG H, YANG F, et al. Feature extraction and detection of planetary gear box fault using unsupervised feature learning [J]. Power System Technology, 2018, 42(11): 3805-3811.

- [9] JING L, ZHAO M, LI P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox[J]. Measurement, 2017, 111: 1-10.
- [10] 曲建岭,余路,袁涛,等.基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J].仪器仪表学报,2018,39(7):134-143.

QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.

- [11] CHEN R, HUANG X, YANG L, et al. Intelligent fault diagnosis method of planetary gearboxes based on convolution neural network and discrete wavelet transform[J]. Computers in Industry, 2019, 106: 48-59.
- ZHAO D, WANG T, CHU F. Deep convolutional neural network based planet bearing fault classification [J].
 Computers in Industry, 2019, 107: 59-66.
- [13] 佘博,田福庆,梁伟阁.基于深度卷积变分自编码网络的故障诊断方法[J]. 仪器仪表学报,2018,39(10):27-35.

SHE B, TIAN F Q, LIANG W G. Fault diagnosis based on a deep convolution variational autoencoder network[J]. Chinese Journal of Scientific Instrument, 2018,39(10): 27-35.

- [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]. Advances in neural information processing systems, 2017: 5998-6008.
- [15] ALIPPI C, DISABATO S, ROVERI M. Moving convolutional neural networks to embedded systems: the alexnet and VGG-16 case [C]. Proceedings of the 17th ACM/IEEE International Conference on Information Processing in Sensor Networks, 2018: 212-223.
- [16] ALASKAR H. Deep learning-based model architecture for time-frequency images analysis [J]. International Journal of Advanced Computer Science and Applications, 2018, 9(12):486-494.

作者简介



孔子迁,2017年于重庆大学获得学士学 位,现为重庆大学机械工程学院硕士研究 生,主要研究方向为设备的智能状态监测与 故障诊断。

E-mail: kongziqian@live.com

Kong Ziqian received his B. Sc. degree from Chongqing University in 2017. He is currently a master student at Chongqing University. His main research interests include intelligent condition monitoring and fault diagnosis of equipment.



邓蕾(通信作者),2001 年于重庆大学 获得硕士学位,2010 年于重庆大学获得博士 学位,现任重庆大学机械工程学院副教授, 主要研究方向为物流与供应链管理、无线传 感器网络研 究与应用、设备健康管理。 E-mail: cqudenglei@163.com

Deng Lei (Corresponding author) received her M. Sc. degree and received her Ph. D. degree both from Chongqing University in 2001 and 2010, respectively. She is currently an associate professor at Chongqing University. Her main research interests include logistic and supply chain management, wireless sensor networks research and application, and equipment health management.