

改进抗噪 1D-CNN 的旋转车轮动平衡状态监测*

周海超¹, 关浩东¹, 王国林¹, 张 宇¹, 赵春来²

(1. 江苏大学汽车与交通工程学院 镇江, 212013)

(2. 东风汽车集团有限公司前瞻技术研究院 武汉, 430056)

摘要 针对实车旋转车轮动平衡状态难以实时监测及预判的问题,提出了一种融合注意力机制的抗噪一维卷积神经网络(noise resistant 1D convolutional neural network, 简称 NRCNN)的旋转车轮动平衡健康状态监测方法。首先,构建 NRCNN 模型,以在实车车轮上添加 3 种不同质量平衡块的方式获得 3 种不同速度下对应的旋转车轮动不平衡状态下的振动信息;其次,以高斯白噪声为噪声输入,对所测旋转车轮不同动平衡状态的振动信息进行处理,获得试验样本数据,并用其进行模型训练;然后,综合运用卷积运算机制和特征变换进行 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding, 简称 t-SNE)可视化显示,实现对不同动平衡状态的分类输出。结果表明,在不同信噪比的工况下,所提出的改进 NRCNN 模型旋转车轮的动平衡状态监测方法相比于传统一维卷积神经网络(1D convolutional neural network, 简称 1D-CNN)模型,展现出更高的诊断准确性,最高可达到 99.95%。

关键词 卷积神经网络;注意力机制;车轮动平衡;状态监测;高斯白噪声

中图分类号 TH17

引 言

车轮动平衡对车辆行驶安全性、操纵稳定性、乘坐舒适性和轮胎使用寿命有着重要影响。在未来汽车智能化的大趋势下,车轮健康状态信息是汽车运行安全状态监测的重要参数之一,车轮故障的早发现、早预判、早解决会对智能汽车安全运行起到保驾护航的作用^[1]。现有对车辆安全运行的状态参数监测主要使用车辆质心加速度或横摆加速度,但其与车轮状态信息之间存在复杂的传播途径,致使所测试的加速度信号难以用来监测旋转车轮状态或车轮状态监测不准确。因此,迫切需要一种可以实时分析数据特征并提供准确诊断结果的智能故障诊断方法^[2]。故障算法的核心是故障提取和模式识别,故障提取的算法包括快速经验模态分解、信号统计特征、傅里叶变换和小波变换等。常用的模式识别算法包括支持向量机、贝叶斯分类器、最近邻分类器及反向传播神经网络等^[2-4]。

智能故障诊断方法已在旋转机械领域中得到广泛应用。Samanta 等^[5]利用优化 3 种不同结构的神经网络对振动信号的时域特征进行提取,以监测泵的故障,3 种算法均取得了良好效果。Tran 等^[6]将

振动信号和电流信号的时域与频域统计特征参数作为样本输入,采用神经模糊推理系统和决策树相结合的方式对感应电机的 6 种故障进行了诊断。Tran 等^[7]利用二维经验模态分解将机器的热成像分解为本征模态函数来计算特征,再将其输入到相关向量机中进行故障分类,准确率均高于自适应模糊神经网络。Yan 等^[8]应用排列熵算法,利用已知的逻辑映射监测出振动信号的动态变化。在此基础上,Wu 等^[9]采用多尺度排列熵的方法对故障轴承振动信号进行特征提取,并利用支持向量机的方法对轴承故障进行诊断。Han 等^[10]以音频和振动信号为研究对象,采用快速傅里叶变换和主成分分析方法提取特征,再使用 K 均值聚类、卷积神经网络和支持向量机对选择的 4 种工作状态进行分类,准确率达到 100%。然而,车轮区域产生的声音复杂多样,致使声波传感器采集到的数据干扰太大^[11],而基于振动信号的方法是利用加速度传感器在旋转机械附近采集振动信号进行特征提取和故障监测,具有成本低、测量速度快的优点^[12],因此笔者采用基于振动信号的方法来监测车轮动平衡状态。

基于深度学习的故障诊断方法利用深度网络逐层提取输入信号的特征,并通过激活函数来增强模

* 国家自然科学基金面上资助项目(52072156, 52272366)

收稿日期:2022-08-04;修回日期:2022-10-28

型的非线性拟合能力,将数据自适应地输入到分类器进行自动分类。因此,采用深度学习的方法不需要人工提取特征,更适用于对车轮健康状态的实时监测。卷积神经网络是深度学习最具代表性的网络之一,已经广泛用于故障诊断、模式识别和医学等领域^[13-14],其最大的优点在于不需要手动提取特征,具有局部连接和共享权值的特点。然而,故障诊断的数据在实际应用中具有局限性,针对一维特征信号,如果 CNN 模型太深、太复杂,容易产生过拟合;如果 CNN 模型太浅,则简单的结构又不能完全学习到有效特征数据。

为了克服上述问题,笔者提出 NRCNN 车轮动平衡状态监测方法,可自适应地快速提取原始振动信号在时间上的相关性,突出振动信号的重要特征信息,而无需考虑其他特征的影响^[15]。本研究将 NRCNN 应用于旋转车轮动平衡状态监测,实现了车轮故障的早发现、早诊断。

1 NRCNN 模型

笔者提出的 NRCNN 模型包含两部分:①对数据采用注意力机制的方法获得相应的权重向量,并与输入数据经过 1 层卷积层后的特征向量在维度上相乘;②将注意力结构连接的输出矩阵构造为 1 个堆叠的 CNN 输入来训练网络。

1.1 传统的 1D-CNN 模型

传统的 1D-CNN 模型一般采用堆叠卷积神经网络结构作为基础结构,CNN 包括卷积层、池化层和全连接层。Zhao 等^[16]提出使用 1 个卷积层和 1 个池化层组成局部特征学习块(local feature learning block, 简称 LFLB)提取数据的局部特征。不同卷积层的卷积核权重矩阵不同,提取的特征也有差别。卷积层与池化层之间一般通过非线性映射函数进行连接来增加模型的非线性拟合能力,本研究主要采用 ReLU 作为激活函数。在卷积运算中,下采样操作(如平均池化层)可以在保证不丢失信息的前提下极大降低输入的数据量,以便缓解计算压力,提高计算性能。

在传统 1D-CNN 模型中,LFLB 可以作为健康状态识别模块。通过多个 LFLB 的连接,网络可以提取输入数据的全局特征,即

$$y_i^l = y_i^{l-1} w_i^l + b_i^l \quad (i = 1, 2, \dots) \quad (1)$$

其中: y_i^l 为第 l 层中第 i 个特征图谱的输出; y_i^{l-1} 为第 l 层中第 i 个特征图谱的输入; w_i^l, b_i^l 分别为输入的权重与偏置。

1.2 通道注意力机制

在一种工况下获得的振动信号与在另一种工况下可能遵循不同的通道特征,这些信号会被汽车悬架振动等噪声所覆盖,对采集信号造成一定的干扰。针对此问题,笔者设计了一种通道注意力机制(channel attention mechanism, 简称 CAM),将更大的权重放在与信号对应特征的通道上,从而抑制其他信息的干扰,实现不同车轮动平衡健康状态的监测。为了提高模型的特征提取能力,减少无关通道的影响,同时获得特征的全局信息,首先,使用 1 个卷积核尺寸为 1×1 的卷积层来聚集通道维数的特征,生成 1 个通道数为 1 的卷积学习结构;其次,进行一步卷积运算,得到 1 组与原数据具有相同尺寸的卷积学习结构;最后,通过 Softmax 激活函数得到最终的注意力机制输出矩阵。注意力机制权重特征图如图 1 所示。




图1 注意力机制权重特征图

Fig.1 Weight characteristic diagram of attention mechanism

将原始信号经过 1 次卷积和池化操作得到一维特征矩阵。首先,本研究在该矩阵上使用卷积核大小为 1×1 的卷积层,得到 1 个通道特征映射卷积层;其次,利用 1 个具有卷积核大小为 32、步长为 31 的卷积层,使其输出与该注意力模块的输入具有相同的尺寸;最后,使用 Softmax 激活函数将上层数据归一化,得到时间注意力特征图,其数学方程可以表示为

$$D_{Att1} = D_{Conv1} w_1 + b_1 \quad (2)$$

$$D_{map} = f(D_{Att1} w_2 + b_2) \quad (3)$$

其中: D_{Conv1} 为原始信号经过 1 次卷积和池化操作得到一维特征矩阵; D_{Att1} 为第 1 层卷积层的权重与偏置; w_1, b_1 为第 1 层卷积层的权重与偏置; D_{map} 为时间注意力特征图; w_2, b_2 为第 2 层卷积层的权重和偏置; f 为 Softmax 激活函数。

得到时间注意力权重矩阵后,将其与特征矩阵在通道维度上相乘得到注意力输出矩阵,使其在不同的通道上对后续运算的影响程度不同。该过程可以表示为

$$A_{out}^k = D_{map}^k D_{Conv1}^k \quad (4)$$

其中: A_{out}^k 为通道注意力机制最终输出的矩阵; k 为特征图的第 k 个维度。

1.3 模型优化技术

每一个激活函数的输入分布会随着前一层参数的变化而发生变化,这使得带有 Tanh 和 Sigmoid 等含有饱和非线性区域的激活函数的模型训练非常困难^[17]。对此,采用批量归一化对特征图进行归一化,使特征的均值和方差趋向于 0 和 1。为了数据梯度的多样性,再对归一化操作附加一定的转换与缩放,该过程可以有效缓解每个卷积层和激活函数之间的梯度爆炸和梯度消失的问题,并能抑制过拟合问题。批量归一化表示为

$$x_2=(x_1-\mu)/\sqrt{\sigma^2+\epsilon}$$
(5)

$$x_3=\gamma y_2+\beta$$
(6)

其中: μ,σ^2 分别为特征数据的均值和方差; ϵ 为避免分母为 0 而添加的常数,一般为 10^{-8} ; γ,β 分别为缩放和偏移量,可由网络训练得到。

1.4 NRCNN 模型的结构与参数

NRCNN 架构如图 2 所示。基于注意力机制的卷积神经网络各层的参数如表 1 所示。该模型由两部分组成:①通道注意力特征提取模块;②LFLB 故障识别模块。

这两个部分可以在数据进入 LFLB 之前分离出来,基于注意力机制的特征提取模块包含 1 个卷积学习结构和注意力机制。该网络在 1 组由 4 096 个采样点组成的信号上运行,选择尺度为 12、步长为 4 的卷积层,并采用 32 个卷积核。在该网络中,注意力机制包含 2 个卷积层来自适应学习相关特征。第 1 个卷积层为 1 个尺度为 1、步长为 1 的卷积结构,将数据展为一维的特征向量,缩减了数据尺寸,可以更有效地提取有关特征。第 2 个卷积层采用 1 个尺寸




图 2 NRCNN 架构
Fig.2 Architecture of NRCNN

为 32、步长为 31 的卷积机构,自适应地获得在第 1 个卷积层中通道维度上不同的 32 个权重。

故障模式识别模块包含 2 个 LFLB、1 个卷积层、2 个批量归一化和 1 个全连接层。LFLB 中,第 1 个卷积层使用 64 个过滤器,因为原数据较大,所以先采用较大的核尺寸为 7,步长为 1。第 2 个卷积层采用相同数量的 64 个过滤器,内核尺寸为 5,步长为 1。每个卷积层后面接有池化层,用来缩减数据特征尺寸,所有池化层的核尺寸和步长都为 2。第 3 个卷积层的过滤器数量为 128,核尺寸为 3,步长为 1。数据传递给 128 个神经元的全连接层之后,再通过 Softmax 激活的输出层进行最终识别。

表 1 基于注意力机制的卷积神经网络各层的参数

Tab.1 Parameters of each layer of convolutional neural network based on attention mechanism					
名称	输入尺寸	卷积核数	卷积核尺寸	步长	输出尺寸
卷积层 1	[batch,4 096,1]	32	12	4	[batch,1 022,32]
池化层 1	[batch,1 022,32]	—	2	2	[batch,511,32]
卷积层 2	[batch,511,32]	64	7	1	[batch,505,64]
池化层 2	[batch,505,64]	—	2	2	[batch,252,64]
卷积层 3	[batch,252,64]	64	5	1	[batch,248,64]
池化层 3	[batch,248,64]	—	2	1	[batch,124,64]
卷积层 4	[batch,124,64]	128	3	1	[batch,122,128]
全连接层	[batch,15 616]	—	—	—	[batch,128]
输出	[batch,128]	—	—	—	[batch,9]

2 试验设置与数据集

2.1 试验设置

为了将模型用于实际的车轮动平衡状态监测，在实车上开展了车轮动平衡试验。试验设备主要包括车轮、LMS 测试系统和加速度传感器。试验轮胎型号为 175/69R13，根据车轮轻微不平衡和严重不平衡状态，分别设置了 3 种动不平衡质量分布，即 0 g（正常状态）、20 g（不平衡状态）和 40 g（不平衡状态），通过将其粘贴在轮辋内侧来等效表征车轮的动不平衡状态。传感器位置如图 3 所示。驾驶员通过对油门控制实现稳定的行驶速度，分别为 30、45 和 60 km/h。测试时，通过安装在车轮轴中心附近的传感器来采集旋转车轮的振动加速度信息。



图3 传感器位置
Fig.3 Acceleration sensor location

2.2 数据集

为了获取不同状态下的旋转车轮振动信息，首先制作了 1 组数据集 F ，该数据集包含 3 种动平衡类型（1 种健康状态和 2 种不平衡状态）在 3 种不同速度下的数据文件，每种数据文件采集时间为 2 min，采样频率为 12 kHz，每类信号的长度为 144×10^4 个点。从 9 种车轮健康状态中分别采集了 2 606 个时域信号样本点，如图 4 所示。

3 NRCNN 模型设计与试验验证

3.1 模型的设计与搭建

本研究使用 Python-Tensorflow 搭建 NRCNN 模型，计算机采用 AMD 5800X 和 NVIDIA RTX3060 图形处理单元用于训练和测试模型。迭代步数设为 500，每步的批处理大小为 72，初始学习率设为 0.001。不同 LFLB 训练结果对比如表 2 所示。




图4 时域信号样本点图
Fig.4 Time domain signal samples diagram

表 2 不同 LFLB 训练结果对比			
Tab.2 Comparison of different LFLB training results			
LFLB 数	训练准确率/%	验证准确率/%	验证损失值
1	97.75	93.57	0.247 8
2	99.95	99.49	0.039 7
3	99.46	96.53	0.156 7
4	98.65	92.14	0.482 1

由表 2 可以看出，2 个 LFLB 的网络结构训练和验证准确率都优于 1 个，说明 2 个 LFLB 更适合于该数据集。随着 LFLB 的增加，训练准确率较为稳定，而验证准确率逐步降低，这说明过拟合现象严重。因此，选择含有 2 个 LFLB 的故障模式识别模块，每 30 步进行 1 次验证。含有 2 个 LFLB 的 NRCNN 模型的准确率如图 5 所示。




图5 含有 2 个 LFLB 的 NRCNN 模型的准确率
Fig.5 Accuracy of the NRCNN model with 2 LFLBs

3.2 模型抗噪性验证

考虑到实际路况中不同环境噪声对采集信号的影响,在原始数据集中加入高斯白噪声,其信噪比^[18](signal noise ratio, 简称 SNR)可以评价噪声对信号的干扰程度,即

$$\text{SNR}_{\text{db}} = 10 \lg \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \tag{7}$$

其中: P_{signal} , P_{noise} 分别为信号和噪声的功率。

图 6 为车轮同一工况下加噪前后的信号对比图。可以看出,含噪信号的幅值增大,则干扰增强,车轮原始信号特征更加难以提取。




图 6 加噪信号对比图
Fig.6 Comparison diagram of noisy signal

笔者通过建立不同的模型来验证所提模型改进部分的优势。首先,主要模型根据通道注意力机制的设置可以分为传统 1D-CNN 和 NRCNN;其次,在划分是否在每个激活函数之前添加批量归一化。不同模型的变量设置如表 3 所示。

表 3 不同模型的变量设置

Tab.3 Different model variable settings		
模型	变量设置	
	CAM	BN层
A	有	有
B	有	无
C	无	有
D	无	无

试验先将数据集 F 按 9:1 的比例划分为训练集和验证集,将训练集分别代入到 4 个模型中进行训练,再通过验证集输入模型中进行测试。不同模型准确率对比如图 7 所示。可以看出,4 个模型在高噪声环境下的准确率都达到 89% 以上,说明均有一定的抗噪能力。当 $\text{SNR}=0$ 时,模型 A 的准确率最高,达到 92.5%。随着噪声干扰的减弱,所有模型的准确率都在进一步提高,在 6~10 dB 环境中可以达到

99% 以上。分别将模型 A 与 B、模型 C 与 D 相比后可以看出,在任意噪声干扰下,模型 A 的准确率都高于 B,模型 C 都高于 D。在高噪声环境中($\text{SNR}=0\sim 4\text{ dB}$),模型 A 比 B 高出 3.24%,模型 C 比 D 高出 2.19%。该结果表明,在 NRCNN 模型的激活函数前加入批量归一化,使数据在各种噪声环境下的特征更易于提取,比未改进前的传统 1D-CNN 有更好的抗干扰能力。同时,在数据集中加入噪声的训练方法能有效抑制模型过拟合,使模型在噪声环境中的性能更好。在加入批量归一化的基础上,将模型 A 与 C 相比,在不同噪声环境下模型 A 的准确率始终高于模型 C,这在 0 和 2 dB 的高噪声环境下尤其明显,分别高出 2.13% 和 1.57%。因此,笔者提出的 NRCNN 模型中引入通道注意力机制,可以对加噪信号卷积后的通道特征赋予权重来改善每个通道特征的提取能力,使模型偏向于有用特征的学习能力。




图 7 不同模型准确率对比图
Fig.7 Comparison of accuracy of different models

为了分析所提方法对车轮不同速度与动平衡状态的敏感性,在 $\text{SNR}=2\text{ dB}$ 的噪声环境下,统计 3 种速度对应的 3 种动平衡状态的识别准确率。不同健康状态准确率如表 4 所示。由表可以看出,本研究所提方法对高速且较大不平衡状态识别准确率在 100% 左右,但在低速时精度有所下降。图 8 为所提方法的准确率混淆矩阵。由图可以看出,误分类主要分布在低速、低质量块情况,这说明车轮正常状态或者轻微动不平衡时特征差异不大。随着车速的增加,所提方法仍然表现出判断准确的特点。

表 4 不同健康状态准确率

Tab.4 Accuracy of different health states			
$v/(\text{km}\cdot\text{h}^{-1})$	m/g	类别标签	准确率/%
30	0	0	93.61
	20	1	95.34
	40	2	100.00
45	0	3	98.12
	20	4	98.56
	40	5	100.00
60	0	6	99.97
	20	7	100.00
	40	8	100.00




图8 准确率混淆矩阵
Fig.8 Accuracy confusion matrix

3.3 NRCNN 的可视化分析

t-SNE 利用高维欧式距离构建一个高维对象之间的概率分布,使得相似的对象有更高的概率被选择,同时在低维空间里构建这些点的概率分布,使得这两个概率分布之间尽可能相似,即同质点之间间隔较小,异质点之间存在大间隔,从而达到降维的效果。

为了研究所改进抗干扰 1D-CNN 模型的内在机理,选择 1 组含噪(SNR=4 dB)信号进行数据降维可视化。不同网络层的数据可视化结果如图 9 所示。由图可知,随着卷积层的深入,特征差异性不断增强。当数据经过第 3 层卷积层时,各类健康状态分布点有了明显的分离趋势,最终完全分开,实现有效分类。此外,随着 NRCNN 的卷积层数增加,每一层的特征提取越来越深入,说明多层卷积层结构对特征提取的必要性。




图9 不同网络层的数据可视化结果
Fig.9 Data visualization results after different network layers

3.4 NRCNN 模型与其他算法的比较

为了对比说明笔者所提算法的优势,将 NRCNN 模型与训练干扰的卷积神经网络(convolu-

tion neural networks with training interference, 简称 TICNN)^[18]和较宽的第 1 层卷积核深度卷积神经网络(deep convolutional neural networks with wide first-layer kernels, 简称 WDCNN)^[19]进行比较。数据集均选择包含 6 种信噪比噪声的同一组车轮振动信号。不同算法的诊断精度对比如图 10 所示。可以看出,在低信噪比范围内,笔者提出的 NRCNN 具有高达 93% 的精度,优势明显;在高信噪比范围内, NRCNN 精度基本在 99%,而另外两种方法精度在 95% 左右。这说明本研究提出的 NRCNN 可应用于不同含噪数据的分析中,且具有相对高的准确率。




图10 不同算法的诊断精度对比
Fig.10 Comparison of accuracy using different algorithms

4 结 论

1) 本研究提出了一种融合注意力机制的改进抗噪 1D-CNN 模型,该模型引入注意力机制与批量归一化的模型优化。所提出的注意力机制采用 1 个尺度为 1 的卷积核对数据各通道进行卷积运算,有效挖掘了数据不同通道间的相关性,提高了模型在噪声背景下的识别能力。批量归一化使得数据流趋向于正态分布,在反向更新时可以更快速有效地找到不同类型之间的区别,确保模型具备较高的识别准确率。

2) 本研究提出的 NRCNN 方法能够实现车轮不同速度和不同动平衡质量下的车轮动态参数的快速准确分类,与传统 1D-CNN 相比,在不同信噪比下 NRCNN 模型在处理动平衡数据时更加准确,最高准确率可达到 99.95%。相比于 WDCNN 和 TICNN, NRCNN 也具有更准确的分类处理能力。

参 考 文 献

- [1] BEHROOZINIA P, TAHERI S, MIRZAEIFAR R. Tire health monitoring using the intelligent tire concept [J]. Structural Health Monitoring, 2019, 18(2): 390-400.
- [2] JIA F, LEI Y G, LIN J, et al. Deep neural networks: a promising tool for fault characteristic mining and

- intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems and Signal Processing, 2016(72/73): 303-315.
- [3] WANG D, PETER W T, GUO W, et al. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis [J]. Measurement Science and Technology, 2010, 22(2): 025102.
- [4] WIDODO A, YANG B S. Support vector machine in machine condition monitoring and fault diagnosis[J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.
- [5] SAMANTA B, AL-BALUSHI K R, AL-ARAIMI S A. Artificial neural networks and genetic algorithm for bearing fault detection[J]. Soft Computing, 2006, 10(3): 264-271.
- [6] TRAN V T, YANG B S, OH M S, et al. Fault diagnosis of induction motor based on decision trees and adaptive neuro-fuzzy inference[J]. Expert Systems with Applications, 2009, 36(2): 1840-1849.
- [7] TRAN V T, YANG B S, GU F S, et al. Thermal image enhancement using bi-dimensional empirical mode decomposition in combination with relevance vector machine for rotating machinery fault diagnosis [J]. Mechanical Systems and Signal Processing, 2013, 38(2): 601-614.
- [8] YAN R Q, LIU Y B, GAO R X. Permutation entropy: a nonlinear statistical measure for status characterization of rotary machines [J]. Mechanical Systems and Signal Processing, 2012, 29: 474-484.
- [9] WU S D, WU P H, WU C W, et al. Bearing fault diagnosis base on multiscale permutation entropy and support vector machine [J]. Entropy, 2012, 14 (8) : 1343-1356.
- [10] HAN S, MANNAN N, STEIN D C, et al. Classification and regression models of audio and vibration signals for machine state monitoring in precision machining systems[J]. Journal of Manufacturing Systems, 2021, 61: 45-53.
- [11] PANZANI G, CORNO M, SAVARESI S M. On the periodic noise affecting wheel speed measurement [J]. IFAC Proceedings Volumes, 2012, 45 (16) : 1695-1700.
- [12] WANG X, MAO D X, LI X D. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network[J]. Measurement, 2021, 173: 108518.
- [13] 熊炘, 郑少帅, 何俊, 等. 改进1DCNN与相似性度量增强的齿轮箱故障识别[J]. 振动、测试与诊断, 2022, 42(2): 242-248.
- XIONG Xin, ZHENG Shaoshuai, HE Jun, et al. Gear-box fault identification based on improved onedimensional convolutional neural network and similarity measure function enhancement [J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(2): 242-248.(in Chinese)
- [14] HAN Y, TANG B P, DENG L. Multi-level wavelet packet fusion in dynamic ensemble convolutional neural network for fault diagnosis [J]. Measurement, 2018, 127: 246-255.
- [15] 赵志宏, 李晴, 李春秀. 基于卷积GRU注意力的设备剩余寿命预测[J]. 振动、测试与诊断, 2022, 42(3): 572-579.
- ZHAO Zhihong, LI Qing, LI Chunxiu. Remaining lifespan prediction of devices based on convolutional GRU attention[J]. Journal of Vibration, Measurement & Diagnosis, 2022, 42(3): 572-579.(in Chinese)
- [16] ZHAO J F, MAO X, CHEN L J. Speech emotion recognition using deep 1D & 2D CNN LSTM networks [J]. Biomedical Signal Processing and Control, 2019, 47: 312-323.
- [17] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille, France: JMLR.org, 2015: 448-456.
- [18] 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.
- [19] ZHANG W, PENG G L, LI C H, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals [J]. Sensors, 2017, 17(2): 425.



第一作者简介:周海超,男,1984年2月生,博士、教授。主要研究方向为轮胎数字化设计与智能轮胎开发。

E-mail:haichaozhou999@163.com

通信作者简介:关浩东,男,1997年12月生,硕士生。主要研究方向为智能轮胎设计与开发。

E-mail:1042341742@qq.com