

结合小波变换与注意力机制的轴承故障诊断*

赵 玲, 孟 阳, 蒋振霖, 吕 颖, 王 航

(重庆交通大学信息科学与工程学院 重庆, 400074)

摘要 针对传统一维轴承振动信号特征表达效果较弱、轴承故障数据时频特征提取困难及其诊断精度较低等问题,提出一种基于小波变换与注意力机制网络(wavelet transform and attention mechanism net,简称 WTA-Net)的轻量化轴承故障诊断方法。首先,通过小波变换将滚动轴承的一维振动时序信号转化为二维时频图;其次,针对网络训练时梯度消失的问题,提出改进的轻量化骨干网络 R-ResNet18 提取二维时频图特征;然后,在网络不同尺度的特征层嵌入时空注意力机制(convolutional block attention module,简称 CBAM),使网络更加关注二维时频图的关键信息特征;最后,采用标签平滑的交叉熵损失函数来对网络模型进行训练。实验结果表明,所提出方法能够精准地辨识不同故障类型和故障严重程度,在凯斯西储大学轴承数据集 10 个分类任务中可达到 99.9% 的分类精度,模型应用在辛辛那提大学智能维护系统(intelligent maintenance systems,简称 IMS)轴承数据集上的分类精度达到了 99.9%,提取的特征信息区分度高,具有良好的泛化性和鲁棒性。

关键词 小波变换;交叉熵损失;注意力机制;故障诊断;振动信号

中图分类号 TH17;TH133

引 言

滚动轴承作为机械设备的关键组成部分之一,一旦发生故障将会造成严重的经济损失^[1],准确及时诊断滚动轴承故障可以最大限度地避免设备性能下降和危险发生。传统故障诊断方法以一维数据中多个特征属性为依据,需要人工提取特征信息并对分类器进行设计,仅适用于特定任务且分类准确率不理想。周超等^[2]提出网格搜索优化序列最小支持向量机的故障诊断方法,在私有数据集上的故障诊断准确率达到 93.75%。小波变换是一种能够提取信号时频域特征的信号处理方法^[3],能够弥补短时傅里叶变换(the short-time Fourier transform,简称 STFT)的单一分辨率缺陷。

近年来,深度学习方法用于轴承故障诊断方面的发展取得了显著进展。游达章等^[4]利用主成分分析(principal component analysis,简称 PCA)降噪的卷积神经网络(convolutional neural network,简称 CNN)识别故障状态,其平均诊断准确率达到 99.49%。陈祝云等^[5]通过引入增强迁移卷积神经网络,显著提升了机械设备在不同工况下的诊断准确度和适用性。赵玲等^[6]提出一种故障特征优化选

择方法,该方法准确率更为精准。李俊卿等^[7]提出了一种电机轴承故障诊断方法,结合卷积神经网络和迁移学习技术,可以有效地对小样本数据进行分类识别,适用于不同工况下的电机轴承故障诊断。唐波等^[8]提出了一种基于 STFT 和卷积神经网络的自适应学习时频特征方法,实现轴承高精度诊断。相比与传统方法,深度神经网络具有更多训练参数,可更好地利用图像中的特征信息,获得更高的分类准确率。但是,上述故障诊断方法存在数据样本不足,用来训练的数据集具有明显的不平衡性;特征图在进行单一池化时可能出现信息损失等问题。

为解决故障数据样本量不足导致的一维数据处理方法精度低和深度学习方法参数量过大的问题,笔者提出了一种基于 WTA-Net 的轻量化轴承故障诊断方法。首先,利用小波变换将一维时域信号映射到二维时频域中;其次,利用卷积神经网络强大的图像处理能力,对小波变换后的时频图进行特征提取;然后,将时频图输入引入通道注意力机制的残差神经网络进行故障模式识别,增大分类任务中不同类别之间的类间差距;最后,利用轻量化模型进行故障检测,缩短模型训练时间并扩大应用场景。

* 国家自然科学基金面上资助项目(6207023978);重庆市教委重点科研资助项目(KJZD-K201900704);重庆市教委重大科学研究资助项目(KJZD-M202400706)

收稿日期:2023-04-03;修回日期:2023-05-21

1 WTA-Net

1.1 故障诊断算法流程

笔者提出的故障诊断算法流程如图1所示。应用小波变换将一维轴承信号转换为二维时频图像,将图像数据划分为训练集、验证集和测试集。训练集用于训练提出的模型,验证集用于评估训练过程中模型在未知数据上的泛化性,测试集用于评估收敛后的神经网络模型的故障诊断性能。提出的模型通过端到端学习故障图像中存在的特征,对图像中是否存在故障以及存在的故障类型进行识别。

1.2 网络结构

笔者提出的WTA-Net结构如图2所示。首先,WTA-Net在数据预处理阶段采用小波变换的方式将一维原始数据转换为二维图像数据;其次,二维时频图像经过带有归一化(batch normalization,简称BN)的骨干网络提取特征后,可以在不同尺度的卷积层分别嵌入CBAM注意力机制,得到关键轴承特




图1 故障诊断方法流程图

Fig.1 Flow chart of fault diagnosis method

征;最后,采用标签平滑的交叉熵损失函数对模型进行训练。




图2 WTA-Net结构

Fig.2 Flowchart of the WTA-Net

1.3 小波变换

采用小波变换的方法将轴承故障信号转换至二维图像。连续小波变换的计算公式为

$$W_{\varphi}(a, b) = \frac{1}{\sqrt{a}} \int x(t) \varphi^* \left(\frac{t-b}{a} \right) dt \quad (1)$$

(a, b ∈ R, a ≠ 0)

其中: $W_{\varphi}(a, b)$ 为小波变化系数; φ 为母小波; φ^* 为复共轭母小波; a 为伸缩因子, a 的大小仅会影响 $W_{\varphi}(a, b)$ 的长度; b 为平移因子。

小波变换的核心是选择适当的小波基函数,当信号波形与所选小波基函数相似时,小波变换会突出该部分,并抑制具有不同形状的信号部分。

Morlet小波变换中,小波基函数由高斯包络下的单频率复正弦函数以及具有指数衰减的高斯函数组成,二者在时域和频域中互相对应。其中:复三角函数对应信号在频域中的振荡;高斯函数对应信号在时域上的有限支撑。小波基函数公式为

$$\Phi(z) = \exp(-t^2/2) \exp(j\omega_0 t) \quad (2)$$

对小波基函数进行伸缩平移,得到一系列小波函数

$$\Phi_{a,b}(z) = 1/\sqrt{a} \exp[-(t-b)^2/2a^2] \times \exp[j\omega_0(t-b)/a] \quad (3)$$

其中: a 为尺度因子; b 为时频因子,实现小波函数在坐标轴上的平移。

通过改变 a 的大小(尺度变换)对小波函数进行

伸缩。 a 越大,函数中心频率越低,函数指数衰减越慢,时域支撑区间越大,则频域带宽越小,频域的分辨率越高; a 越小时,变化则相反。

由于小波时频图能够提供更为丰富的信息,因此在理论上用其进行诊断,能够获得更好的稳定性和准确性。笔者在数据处理过程中选择对原始轴承数据做 Morlet 小波变换,将原始一维数据扩维为二维时频图。小波变换时频图如图 3 所示。




图 3 小波变换时频图

Fig.3 Time-frequency diagram of wavelet transform

1.4 骨干网络

骨干网络采用改进的 R-ResNet18 网络,该网络采用 RReLU 激活函数。RReLU 激活函数对负值赋予一个非零斜率,尽可能保留负半轴有效信息。RReLU 的数学表达式为

$$f(x) = \begin{cases} x & (x \geq 0) \\ ax & (x < 0) \end{cases} \quad (4)$$

其中: x 为神经元的输入;参数 a 服从均匀分布。

残差单位可表示为

$$\begin{cases} y_1 = h(x_l) + F(x_l, W_l) \\ x_{l+1} = f(y_1) \end{cases} \quad (5)$$

其中: x_l 和 x_{l+1} 分别为第 l 个残差单元的输入与输出; R 为残差函数^[9],可以理解为从结构学到的残

差; $h_l(x) = x_l$ 为单位映射; f 为单元的激活函数。

由式(5)推导出网络中从 L 层到 $L+M$ 层学习到的特征为

$$x_{L+M} = x_L + \sum_{i=L}^{L+M-1} F(x_i, W_i) \quad (6)$$

如图 4 所示,考虑到经过小波变换得到的二维时频图之间存在差异相比于一维数据能够更适用于轴承故障分类,同时 ResNet18 中具有残差连接结构可保留二维时频图信息关键特征^[10],笔者使用 RReLU 函数替换 ResNet18 残差块结构中的 ReLU 激活函数,以防止梯度消失导致网络性能下降。




图 4 改进残差块结构图

Fig.4 Structure diagram of improved residual block

1.5 CBAM 注意力模块

笔者提出的 WTA-Net 网络采用了 CBAM 注意力机制,如图 5 所示,结合了通道与空间注意力进行特征图处理,以更精细地关注重要区域,提高准确性。具体来说,CBAM 机制使用通道注意力调整通道特征图,通过计算每个通道的重要性来突出最重要的通道。同时,使用空间注意力加权原始特征图,以突出最重要的空间位置。这种注意力机制可以帮助网络更好地理解图像中的特征,提高图像分类和检测的准确性。




图 5 CBAM 注意力机制

Fig.5 CBAM attention mechanism

1.5.1 通道注意力机制

本研究中故障诊断为 10 分类任务,因相同故障的时频图之间差异较小,模型对不同损伤尺寸的相

同故障图像进行分类较为困难,笔者在通道维度使用通道注意力机制^[11]可提升模型分类精度。同时采用全局最大池化和全局平均池化可以避免池化操作中的信息丢失,在此之后使用多层感知机(multilayer perceptrons,简称MLP)拼接全连接层,并使用Sigmoid激活函数进行输出获得特征图的通道维度的权重矩阵,从而实现对重要信息的提取。

通道注意力机制的公式为

$$M_c(F) = \sigma(\text{MLP}(F_{\text{avgpool}}) + \text{MLP}(F_{\text{maxpool}})) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + W_1(W_0(F_{\text{max}}^c))) \quad (7)$$

其中: F 为输入网络的特征图; W_0, W_1 为全连接层; σ 表示Sigmoid函数。

加入通道注意力机制的残差网络块如图6所示。




图6 通道注意力机制结构图

Fig.6 Structure diagram of channel attention mechanism

1.5.2 空间注意力机制

特征图不同区域对特征识别的作用不同,使用空间注意力可以帮助模型学习特征图之间的关系,并找到重要部位进行处理。将特征图分成多个区域,采用平均池化生成 $F_{\text{avg}}^s \in R^{1 \times H \times W}$ 和最大池化生成 $F_{\text{max}}^s \in R^{1 \times H \times W}$ 2个特征图,并将其连成二通道特征图,通过卷积生成空间注意力图。空间注意力机制结构图图7所示。

$$M_s(F) = \sigma(f^{7 \times 7}([F_{\text{avgpool}}^s; F_{\text{maxpool}}^s])) = \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (8)$$

其中: σ 表示Sigmoid激活函数; $f^{7 \times 7}$ 表示卷积处理;卷积核大小为 7×7 。




图7 空间注意力机制结构图

Fig.7 Structure of spatial attention mechanism

1.6 损失函数

在本实验中,故障检测是一个多分类任务,为了使模型更加有效提取出辨别性强的轴承损伤特征,采用交叉熵函数作为损失函数,选择Softmax作为分类器。交叉熵函数的表达式为

$$L_{\text{Softmax}} = - \sum_{i=1}^N q_i \log_a \frac{e^{w_i^T f}}{\sum_{k=1}^N e^{w_k^T f}} \quad (9)$$

其中: N 为类别数; w_i 为全连接层第 i 个类别的权重向量;当样本 i 的真类别为 c 时,整合函数取1,否则取0。

为防止模型对时频图片过拟合,改善模型的泛化性能,笔者采用带有标签平滑技术的交叉熵损失函数 q_i ,其表达式为

$$q_i = \begin{cases} \frac{\epsilon}{N} & (y \neq i) \\ 1 - \frac{N-1}{N} \epsilon & (y = i) \end{cases} \quad (10)$$

其中: ϵ 为标签平滑参数,这里 ϵ 设为0.1。

综合来看,R-ResNet18网络和CBAM注意力机制对深度学习模型的训练和泛化性能都有了重要的改善作用。

2 实验结果与分析

2.1 数据集

笔者采用凯斯西储大学轴承数据集和辛辛那提大学IMS轴承数据集进行实验分析。表1为凯斯西储大学轴承数据集。选用驱动端轴承数据,选择轴承故障的3种损伤尺寸(0.017 78, 0.035 56和0.053 34 cm)将轴承划分为10种状态标签。表2为第1组IMS轴承数据集,包含了4种轴承监测数据。通道1的数据为正常,通道5的数据为内圈故障,通道3的数据为外圈故障,通道7的数据为滚珠故障。将轴承划分为4种标签。

表 1 凯斯西储大学轴承数据集
Tab.1 Case Western Reserve University bearing data set

类型	损伤/cm	代号	标签	训练数量	验证数量	测试数量
正常	—	N	0	147	42	21
内圈损伤	0.017 78	IR1	1	147	42	21
	0.035 56	IR2	2	147	42	21
	0.053 34	IR3	3	147	42	21
外圈损伤	0.017 78	OR1	4	147	42	21
	0.035 56	OR2	5	147	42	21
	0.053 34	OR3	6	147	42	21
滚珠损伤	0.017 78	RB1	7	147	42	21
	0.035 56	RB2	8	147	42	21
	0.053 34	RB3	9	147	42	21

表 2 IMS 数据集
Tab.2 IMS data set

类型	代号	标签	训练数量	验证数量	测试数量
正常	N	0	140	40	20
内圈损伤	IR1	1	140	40	20
外圈损伤	OR1	2	140	40	20
滚珠损伤	RB1	3	140	40	20

2.2 实验细节

选用优化器 Adam 对模型参数进行优化。在实验中使用多组初始学习率,发现当学习率接近 0.000 1 时,模型的收敛速度最快。经实验分析,选用 0.000 3 作为初始学习率并进行训练。将学习率衰减周期设为 30 个周期,衰减率设为 0.5。当训练时间达到 30 个周期时,该模型的损失接近平滑,故设模型训练时间为 100 个周期。

2.3 评估指标

基于准确性、Kappa 评分、 F_1 评分、敏感性、特异性和精确度对所提出方法的性能进行评估。以模型在轴承故障的敏感性、精度和特异性的平均值作为评价指标。将预测结果中的正样本数设为 TP,负样本数设为 FP,假阴性数设为 FN,真阴性数设为 TN,各类别的评价指标如下。

对于多分类任务,最直接的度量指标是全类准确率,即正确分类样本的数量与总样本数量的比例,表达式为

$$A = \frac{TP + TN}{TP + TN + FP + FN} \tag{11}$$

精确度是预测阳性的样本数量与真正阳性的样本数量的比例,表达式为

$$P = \frac{TP}{TP + FP} \tag{12}$$

敏感度是被预测阳性的真阳性样本的比例,数值越高,表示漏检的阳性样本越少,表达式为

$$S = \frac{TP}{TP + FN} \tag{13}$$

特异性表示被预测为阴性的真阴性样本的比例,值越大,表示阴性样本的假阳性较少,表达式为

$$E = \frac{TN}{TN + FP} \tag{14}$$

F_1 评分为灵敏度和精确度的求和平均值,用于对模型进行综合评价,表达式为

$$F_1 = 2 \frac{SP}{S + P} \tag{15}$$

2.4 消融实验

2.4.1 不同骨干网络实验分析

为体现提出的模型在故障诊断任务中的效果,笔者将 MobileNetV2、AlexNet、VGG16、GoogLeNet、InceptionNetV3 和 ResNet18^[12] 等神经网络模型用于故障诊断中。其中:AlexNet、VGG16 为无特殊设计的模型;MobileNet、ResNet18 为参数量较低的轻量化模型;InceptionNetV3 为利用多尺度特征融合的神经网络模型。

不同骨干网络的消融实验结果如表 3 所示。可见,笔者提出的模型各项指标相比于 AlexNet 准确率、 F_1 分数、敏感度、特异性和精确度分别高了 1.75%、1.75%、1.74%、1.74% 和 1.75%,与 InceptionNetV3 相比,分别提高了 0.37%、0.26%、0.36%、0.32% 和 0.14%。

表 3 不同骨干网络的消融实验结果
Tab.3 Ablation results of different backbone networks

模型	准确率	F_1 评分	敏感度	特异性	精确度
MobileNetV2	98.71	98.72	98.73	98.75	98.72
AlexNet	98.24	98.24	98.25	98.25	98.24
VGG16	98.21	98.23	98.24	98.24	98.23
GoogLeNet	99.54	99.57	99.57	99.57	99.57
InceptionNetV3	99.62	99.73	99.63	99.67	99.85
提出的模型	99.99	99.99	99.99	99.99	99.99

图 8 为 ϵ 的超参数分析。可以看出,当 ϵ 的值为 0.1 时,精度达到了 99.99%,性能表现最好。




图8 ϵ 的超参数分析

Fig.8 ϵ hyperparameter analysis

本项工作中,采用Pytorch作为深度学习的框架,并在内存为24 GB的NVIDIA GeForce 3090 GPU上进行训练,操作系统采用Win10。

参数量与训练时间对比如表4所示。笔者提出模型的各项指标相比于AlexNet,参数量降低了约95%,但训练时间只增加了约15%。

表 4 参数量与训练时间对比		
Tab.4 Comparison of parameter quantity and training time		
模型	参数量	训练时间/s
AlexNet	57,044,810	566.780
MobileNetV2	2,236,682	556.342
VGG16	134,301,514	1 186.022
GoogLeNet	9,960,638	700.691
InceptionNetV3	24,371,444	2 144.008
提出模型	2,863,906	669.156

2.4.2 空间注意力模块

空间注意力模块的消融实验结果如表5所示。加入空间注意力模块后,相对于R-ResNet18,R-ResNet18+SAM方法在准确率、 F_1 评分、特异性和精确度方面,分别提高了0.06%、0.04%、0.13%和0.10%。

表 5 空间注意力模块的消融实验结果					
Tab.5 Experimental results of ablation of spatial attention module					
网络	准确率	F_1 评分	敏感度	特异性	精确度
R-ResNet18	99.52	99.55	99.55	99.55	99.55
R-ResNet18+SAM	99.58	99.59	99.55	99.68	99.65

2.4.3 通道注意力模块

通道注意力模块的消融实验结果如表6所示。加入通道注意力模块后,相对于R-ResNet18,R-ResNet18+SAM方法在准确率、 F_1 分数、特异性和精确度方面,分别提高了0.04%、0.06%、0.08%和0.07%。

表 6 通道注意力模块的消融实验结果					
Tab.6 Experimental results of ablation of channel attention module					
网络	准确率	F_1 评分	敏感度	特异性	精确度
R-ResNet18	99.52	99.55	99.55	99.55	99.55
R-ResNet18+SAM	99.56	99.61	99.60	99.63	99.62

2.4.4 CBAM注意力模块

CBAM注意力模块的消融实验结果如表7所示。加入CBAM注意力模块后,相对于R-ResNet18,R-ResNet18+SAM方法在准确率、 F_1 分数、特异性和精确度方面,分别提高了0.47%、0.44%、0.44%和0.44%。

表 7 CBAM注意力模块的消融实验结果					
Tab.7 Experimental results of ablation of CBAM attentional module					
网络	准确率	F_1 评分	敏感度	特异性	精确度
R-ResNet18	99.52	99.55	99.55	99.55	99.55
R-ResNet18+SAM	99.99	99.99	99.99	99.99	99.99

图9为训练损失曲线。模型训练的准确精度如图10所示。可以看出,模型损失不断下降,准确精度不断上升,说明模型效果较好。




图9 训练损失曲线

Fig.9 Training loss curve




图10 模型训练的准确精度

Fig.10 Accurate precision of model training

图11为测试样本的混淆矩阵。可见,所提出方法在凯斯西储大学轴承数据集10个分类任务中可达到99.9%的分类精度,不存在误判情况,诊断结果优异。




图 11 测试样本的混淆矩阵
Fig.11 Confusion matrix of the test sample

2.5 对比实验

表 8 为笔者所提出模型与其他模型在凯斯西储大学轴承数据集上的对比结果。模型包括飞蛾火焰优化支持向量机 (moth-flame optimization-support vector machine, 简称 MFO-SVM)、深度信念网络 (deep belief network, 简称 DBN)、加权深度卷积神经网络 (weighted deep convolutional neural network, 简称 WDCNN)、深度卷积长短期记忆网络 (deep convolutional long short term memory network, 简称 DCLSTM)、卷积神经网络-长短期记忆网络 (convolutional neural network-long short-term memory network, 简称 CNN-LSTM) 和 WTA-Net。

表 8 提出模型与其他模型在凯斯西储大学轴承数据集上的对比

Tab.8 The comparison between the proposed model and other models on the Case Western Reserve University bearing data set

诊断模型	准确率	精确率	灵敏度	召回率	F_1 评分
MFO-SVM	98.50	98.50	98.46	—	98.47
DBN	98.43	98.55	98.48	98.35	98.51
WDCNN	98.88	98.90	98.88	99.00	99.89
DCLSTM	99.96	99.96	99.97	99.96	99.96
CNN-LSTM	99.83	99.83	99.81	99.50	99.81
WTA-Net	99.99	99.99	99.99	99.99	99.99

表 9 为所提出模型与其他模型在 IMS 轴承数据集上的对比结果。模型包括剩余使用寿命 (remaining useful life, 简称 RUL)、变点检测 (change point detection algorithm, 简称 CPD)、稀疏自动编码器长短期记忆网络 (sparse encoder architecture-long short term memory network, 简称 SAE-LSTM)、主成分分析线性自注意力模型 (principal component

analysis linear attention transform model, 简称 PCA-LATM)、深度卷积神经网络 (deep convolutional neural network, 简称 DCNN) 和 WTA-Net。

表 9 提出模型与其他模型在 IMS 轴承数据集上的对比
Tab.9 The comparison between the proposed model and other models on the IMS bearing data set

诊断模型	准确率	精确率	灵敏度	召回率	F_1 评分
RUL	95.94	95.96	95.88	96.03	95.91
CPD	97.91	98.01	97.98	98.01	97.99
SAE-LSTM	99.78	99.80	99.80	—	99.80
PCA-LSTM	99.75	99.73	99.75	99.70	99.72
DCNN	99.55	99.56	99.50	99.54	99.53
WTA-Net	99.99	99.99	99.99	99.99	99.99

可见,笔者所提出方法在 2 个轴承数据集上的指标准确率、精确率、召回率和 F_1 评分都达到了 99.99%, 模型的综合性能优异。

3 结束语

笔者提出一种基于小波变换与注意力机制网络的轻量化轴承故障诊断方法。首先,对原始振动信号进行小波变换,实现一维数据到二维时频图的转换;其次,构建改进的 R-ResNet18 网络用于故障诊断,缓解 ReLU 激活函数存在梯度消失问题;然后,在 WTA-Net 中引入 CBAM 注意力机制,增强对同一故障类型下的不同损伤尺度的时频图敏感度;最后,采用标签平滑的交叉熵损失函数来减少网络的过拟合问题,并在凯斯西储大学轴承数据集和 IMS 轴承数据集上进行实验验证。结果表明,所提出方法能够准确识别轴承在不同故障状态和严重程度下的运行信息,准确率可达 99.9%, 证明了该方法的有效性。

参 考 文 献

[1] TIAN Y L, LIU X Y. A deep adaptive learning method for rolling bearing fault diagnosis using immunity [J]. Tsinghua Science and Technology, 2019, 24 (6): 750-762.

[2] 周超, 曹春平, 孙宇. 利用 GS 优化 SM-SVM 的滚动轴承故障诊断方法研究 [J]. 机械设计与制造, 2020(6): 16-19.

ZHOU Chao, CAO Chunping, SUN Yu. Research on rolling bearing fault diagnosis method based on GS opti-

- mized SM-SVM [J]. Machinery Design & Manufacture, 2020(6): 16-19. (in Chinese)
- [3] MENG L, SU Y H, KONG X J, et al. Intelligent fault diagnosis of gearbox based on differential continuous wavelet transform-parallel multi-block fusion residual network[J]. Measurement, 2023, 206: 112318.
- [4] 游达章, 陈林波, 张业鹏, 等. 基于PCA-CNN的滚动轴承故障诊断方法研究[J]. 机床与液压, 2021, 49(19): 172-177.
- YOU Dazhang, CHEN Linbo, ZHANG Yepeng, et al. Study on fault diagnosis methods of rolling bearing based on principal component analysis and convolutional neural network[J]. Machine Tool & Hydraulics, 2021, 49(19): 172-177. (in Chinese)
- [5] 陈祝云, 钟琪, 黄如意, 等. 基于增强迁移卷积神经网络的机械智能故障诊断[J]. 机械工程学报, 2021, 57(21): 96-105.
- CHEN Zhu Yun, ZHONG Qi, HUANG Ruyi, et al. Intelligent fault diagnosis for machinery based on enhanced transfer convolutional neural network[J]. Journal of Mechanical Engineering, 2021, 57(21): 96-105. (in Chinese)
- [6] 赵玲, 龚加兴, 黄大荣, 等. 基于Fisher Score与最大信息系数的轴承箱故障特征选择方法[J]. 控制与决策, 2021, 36(9): 2234-2240.
- ZHAO Ling, GONG Jiaxing, HUANG Darong, et al. Bearing box fault feature selection method based on fisher score and maximum information coefficient[J]. Control and Decision, 2021, 36(9): 2234-2240. (in Chinese)
- [7] 李俊卿, 刘静. 结合卷积神经网络和迁移学习的电机轴承故障诊断方法[J]. 华北电力大学学报(自然科学版), 2023, 50(1): 76-83, 91.
- LI Junqing, LIU Jing. Fault diagnosis method of motor bearing based on CNN and transfer learning[J]. Journal of North China Electric Power University (Natural Science Edition), 2023, 50(1): 76-83, 91. (in Chinese)
- [8] 唐波, 陈慎慎. 基于深度卷积神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2020, 34(3): 88-93.
- TANG Bo, CHEN Shenshen. Method of bearing fault diagnosis based on deep convolutional neural network [J]. Journal of Electronic Measurement and Instrument, 2020, 34(3): 88-93. (in Chinese)
- [9] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA: IEEE, 2016: 770-778.
- [10] LIANG P F, WANG W H, YUAN X M, et al. Intelligent fault diagnosis of rolling bearing based on wavelet transform and improved ResNet under noisy labels and environment[J]. Engineering Applications of Artificial Intelligence, 2022, 115: 105269.
- [11] 吴静然, 丁恩杰, 崔冉, 等. 采用多尺度注意力机制的旋转机械故障诊断方法[J]. 西安交通大学学报, 2020, 54(2): 51-58.
- WU Jingran, DING Enjie, CUI Ran, et al. A diagnostic approach for rotating machinery using multi-scale feature attention mechanism[J]. Journal of Xi'an Jiaotong University, 2020, 54(2): 51-58. (in Chinese)
- [12] CHEN Z, JIANG Y, ZHANG X Y, et al. ResNet18 DNN: prediction approach of drug-induced liver injury by deep neural network with ResNet18[J]. Briefings in Bioinformatics, 2022, 23(1): bbab503.



第一作者简介:赵玲,女,1979年11月生,博士、教授。主要研究方向为动态系统的故障诊断与容错控制、复杂系统的分析与设计。曾发表《Smooth control design for adaptive leader-following consensus control of a class of high-order nonlinear systems with time-varying reference and unknown control directions》(《Transactions of the Institute of Measurement and Control》2019, Vol. 49, No.1)等论文。

E-mail:zhao.ling@163.com