DOI:10.16450/j.cnki.issn.1004-6801.2021.04.012

改进抗干扰 CNN 的变负载滚动轴承损伤程度识别*

董绍江1, 裴雪武1, 吴文亮1, 汤宝平2, 赵兴新3

(1. 重庆交通大学机电与车辆工程学院 重庆,400074) (2. 重庆大学机械传动国家重点实验室 重庆,400044) (3. 重庆长江轴承股份有限公司 重庆,401336)

摘要 针对强噪声、变负载工况下滚动轴承损伤程度难以识别的问题,提出了一种基于改进抗干扰卷积神经网络 (anti-interference convolutional neural network, 简称 ACNN)的变负载工况下轴承损伤程度识别新方法。首先, 对滚 动轴承的一维振动信号进行预处理,得到标签化的数据样本,分为训练集和测试集;其次,将注意力机制引入到卷积 神经网络的各个特征提取层中以建立特征提取通道之间的联系,得到基于改进 ACNN 的变负载工况下轴承损伤程 度识别模型;然后,将训练集数据输入到改进ACNN中进行学习,将得到的识别模型应用于测试集,输出损伤程度 识别结果,在训练过程中,为了提高模型的抗干扰能力,将 Dropout 算法引入到卷积层,为抑制过拟合,对原始训练 样本进行加噪处理;最后,通过滚动轴承损伤程度模拟试验,在变工况下进行测试。结果表明,在噪声环境中所提方 法能更准确地实现变负载工况下的轴承损伤程度识别。

关键词 滚动轴承; 损伤程度识别; 注意力机制; 抗干扰卷积神经网络 中图分类号 TH113.1; TH133.3

引 言

滚动轴承是机械系统中关键零部件之一,其损 伤程度过大可能会导致机器停机,造成巨大的经济 损失[1]。在实际工作过程中,不同负载工况下的振 动信号难以比较,且振动信号容易被噪声污染[2]。 因此,对噪声环境下的轴承故障振动信号及时识别, 可以有效避免故障的持续恶化[3]。

基于人工智能的故障诊断方法已广泛应用于旋 转机械的故障诊断,并取得较好的效果。目前,国内 外学者主要从信号特征提取与模式分类实现轴承的 故障诊断。Li等[4]提出了采用分层符号动态熵从轴 承振动信号中提取故障特征的方法,输入到二叉树 支持向量机对不同的故障类型进行分类。戴洪德 等[5]采用样本分位数原理提取滚动轴承故障数据排 列熵的特征,并将其作为特征量输入到支持向量机 中进行识别。Harmouche等[6]提出的全局光谱分析 方法使用快速傅里叶变换和包络检测对信号进行预 处理,利用线性判别器进行故障分类。以上诊断方 法需要对原始振动信号进行预处理,存在丢失重要 时域特征的可能,且算法组合的通用性不能保证。

部分学者提出基于深度学习的故障诊断方法,

该方法无需对原始信号进行预处理,就能实现从端 到端的轴承故障诊断。孙文珺等[7]提出基于稀疏自 动编码的深度神经网络模型,在稀疏编码器中引入 去噪编码,结合反向传播算法和Dropout算法,实现 了在非监督学习下的感应电动机故障诊断。在样本 不足时,稀疏编码的学习不强,为解决模型的过拟合 问题,需要设计合适的特征提取器与分类器组合来 实现智能诊断。卷积神经网络是一种有监督的深度 学习算法。Janssen等[8]利用卷积神经网络对齿轮 箱中的轴承、齿轮等进行故障诊断,该方法将离散傅 里叶变换和浅层卷积神经网络相组合,得到的故障 诊断率比传统算法的高出6%。Zhang等[9]提出了 基于训练干扰算法的卷积神经网络模型,该方法直 接将原始振动信号作为网络模型的输入,可以避免 丢失重要的时域特征,成功实现了变工况负载下的 轴承故障诊断。佘博等[10]提出用深度卷积变分自 编码网络训练由傅里叶变换得到的频域数据。以上 模型在轴承故障诊断方面取得了不错的效果,但是 没有同时考虑到工业现场中不可避免的噪声和轴承 服役时承受的工况变化问题。

笔者提出一种基于改进 ACNN 方法的变负载 工况下滚动轴承损伤程度识别方法。首先,将

^{*} 国家自然科学基金资助项目(51775072);重庆市科技创新领军人才支持计划资助项目(CSTCCCXLJRC201920) 收稿日期:2020-05-15;修回日期:2020-06-26

Dropout算法引入到卷积层;其次,在各个特征提取层中引入注意力机制,为抑制数据过拟合,对标签化训练样本进行加噪处理;然后,根据加噪样本训练改进的ACNN得到轴承损伤程度识别模型;最后,通过模拟工业现场的噪声环境和变负载工况下的滚动轴承损伤程度识别试验,证明了所提方法的可行性和有效性。

卷积神经网络的学习过程主要分为正向传播和反向参数更新。正向传播由多个交替连接的卷积层(convolutional layer,简称 Conv)、池化层(pooling layer,简称 Pool)和若干个完全连接层(fully connected layer,简称 FCL)组成。正向传播的参数通过反向传播算法进行优化,卷积神经网络(convolutional neural network,简称 CNN)的训练过程如下。

1.1 前向传播过程

卷积层的前向传播阶段是使用卷积核对输入信号特征的局部区域进行卷积运算,即通过对上一卷积层中的节点计算出下一卷积层中节点的过程,并产生相应的特征。卷积层的输入表达式为

$$\mathbf{z}^{l+1} = \mathbf{x}^l + \mathbf{w}^l + \mathbf{b}^l \tag{1}$$

其中: \mathbf{w}^l 为第l层的卷积核; \mathbf{b}^l 为偏置项; \mathbf{x}^l 为上一层的输出。

$$x^{l+1} = f(z^l) \tag{2}$$

其中: f(•)为激活函数。

笔者拟采用的非线性激活函数为修正线性单元 (rectified linear unit, 简称 ReLU)[11]。ReLU激活函数为

$$f(x) = \max\{0, x\} \tag{3}$$

池化层与卷积层共同构成神经网络的特征提取 层。池化层进行降采样操作,主要是减少神经网络 的参数。池化层的算法为

$$d_i^l = \max\{U_i\} \tag{4}$$

其中: d_i 为第i个池化层的第b个输出; U_i 为 x_i 的第i个特征矩阵; x_i 为 z_i 的激活值。

特征提取过程结束后,全连接层将提取出的特征进行分类。输出层将Softmax函数作为激活函数输出损伤程度类型,将神经网络的输出值固定在0~1之间,表示不同事件发生的概率。

1.2 反向参数更新过程

反向参数更新过程即是对神经网络进行权值优 化的过程。笔者提出的神经网络目标函数包括交叉 熵和L2正则化。目标函数的算法为

$$Loss(\boldsymbol{w}, \boldsymbol{b}) = H(\boldsymbol{y}^{-}, \boldsymbol{y}) + \beta \sum \boldsymbol{w}^{2}$$
 (5)

其中: $H(y^-,y)$ 为 y^- 和y两个概率之间的分布距离; y^- 为预测分布;y为输入参数的相应标签值; β 为模型复杂损失在总损失中的比例; $\sum_{w} w^2$ 为模型的复杂程度。

笔者在训练神经网络的过程中采用学习率随机 梯度下降法,学习率用来控制残差反向传播的强 度。权重和偏置值的更新算法分别为

$$\mathbf{w}_{ij}^{l} = \mathbf{w}_{ij}^{l} - \alpha \frac{\partial}{\partial \mathbf{w}_{ij}^{l}} \operatorname{Loss}(\mathbf{w}, \mathbf{b})$$
 (6)

$$\boldsymbol{b}_{i}^{l} = \boldsymbol{b}_{i}^{l} - \alpha \frac{\partial}{\partial \boldsymbol{b}_{i}^{l}} \operatorname{Loss}(\boldsymbol{w}, \boldsymbol{b})$$
 (7)

其中: α 为学习率; $\frac{\partial \text{Loss}(\bullet)}{\partial}$ 为损失函数的梯度。

1.3 模型优化技术

为提升模型泛化能力,引入Dropout算法^[10];为加快模型的收敛速度,引入批量归一化处理(batch normalization,简称BN)。Dropout算法将隐层神经元按一定比例随机置0,当设置的Dropout率为90%时,即神经网络节点并非全部存活,有10%的神经元不参与正向传播与反向参数更新过程,以此降低模型过拟合的风险。另外,当卷积核被随机置0,Dropout算法可以看做是给卷积区域引入了噪声以增强模型的抗干扰能力^[10]。BN层通常在ReLU激活功能前进行,BN层将输出数据映射到非线性函数,可以迫使数据分布呈标准正态分布,输入到该层的数据将落入激活函数的敏感区域,以避免梯度消失^[12]。BN层的算法如下

$$\mu_B = \frac{1}{m} \sum_{i=1}^m z_i^l \tag{8}$$

$$\delta_B^2 = \frac{1}{m} \sum_{i=1}^m (z_i^l - \mu_B)^2$$
 (9)

$$\hat{\mathbf{z}}_{i}^{l} = \mathbf{z}_{i}^{l} - \mu_{B} / \sqrt{\delta_{B}^{2} + \epsilon}$$
 (10)

$$Z_i^l = \gamma_i^l \hat{z}_i^l + \beta_i^l \tag{11}$$

其中:m为每个小批量中的数量; ε 为增加数值稳定性的小常数; γ_i 为缩放参数; β_i 为移位参数; Z_i 为第1个BN层的第i个节点的输出。

2 改进的抗干扰卷积神经网络

注意力机制(attention mechanism,简称 AM)在自然语言处理、语音识别及图像识别领域应用广泛,其核心是选出对当前任务目标更重要的信息^[13]。注意力机制的目的是帮助神经网络学习权重分布,即对数据进行加权学习。笔者将注意力机制引入到ACNN的各个特征提取层中,建立特征提取通道之间的联系,从而提取出更加敏感的深层特征。在深度学习模型中,Sigmoid函数通常用于对特征进行加权处理,不同的权重大小表示特征的不同重要程度。基于注意力机制的ACNN模块的实现步骤包括特征提取层的特征聚合、全连接层的权重生成和特征通道的权重分配^[14]。实现步骤如下

$$V_j = \frac{1}{N_i} \sum_i Z_j^i \tag{12}$$

$$d_i = ReLU(\mathbf{w}_1, \mathbf{V}_i) \tag{13}$$

$$Q_i = \text{Sigmoid}(w_2, d_i) \tag{14}$$

$$Z_{I} = Q_{i} \cdot Z_{i} \tag{15}$$

其中: V_j 为第j个特征聚合生成的特征向量; Z_j 为第j个特征映射中的第i个特征向量; N_j 为单个特征的映射长度; w_1 和 w_2 分别为两个全连接层的连接权重; d_j 为第1全连接层的输出; Q_i 为得到的权重向量; Z_j 为每一个特征提取层的输出特征; Z_j 为每一特征提取层输出的新特征。

基于注意力机制的ACNN模块如图1所示。

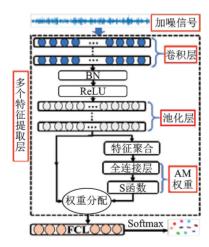


图1 基于注意力机制的 ACNN 模块图

Fig.1 ACNN module diagram based on attention algorithm

3 模型架构设计与试验对比验证

3.1 数据来源和样本制作

试验数据来自美国凯斯西储大学轴承故障信

号。由于轴承在实际运行过程中,极少在0 W 负载 工况下工作,故笔者分别选取了轴承在735 W~ 2 205 W 负载工况下工作时的振动信号。信号的采 样频率为12kHz,实验中的SKF6205轴承通过电火 花加工凹槽方式,在其内圈、外圈和滚动体加工出 0.177 8 mm, 0.355 6 mm 和 0.533 4 mm 的单点故 障,另外还包含正常轴承在内的共10类故障类型。 笔者在获得轴承信号数据集时,采用重叠采样方法 将一维信号数据切分为每类故障200个样本,每个 样本包含2048个数据点。这不仅增加了训练样本 数量,还增强样本数据之间尽可能多的相关性。制 作成包含 2 000 个数据样本的标签 $\ell(F_1,F_2,F_3)$ 数据 集,且每个数据集仅包含一种负载下的10种轴承运 行状态。此外,在训练样本中加入高斯白噪声,增大 损伤样本的同时,还可以避免网络参数过多而引起 的过拟合问题,以提高网络的鲁棒性[15]。

3.2 基于ACNN模型的设计与搭建

针对在噪声环境中和变负载工况下的滚动轴承 一维振动信号,提出的改进ACNN识别模型如图 2 所示。

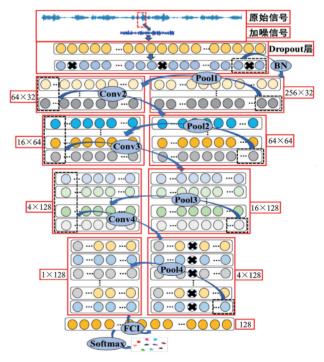


图 2 改进 ACNN 识别模型结构图

Fig.2 Improved ACNN recognition model structure diagram

笔者提出的ACNN识别模型包含11层:1个输入层,4个卷积层,4个池化层,1个全连接层和1个Softmax层。ACNN模型参数如表1所示。

表 1 提出的 ACNN 模型参数 Tab.1 The parameters of proposed ACNN

| 网络层 | 参数 | 输出 特征尺寸 |
|-----------|----------------|-----------------|
| 卷积层1 | 卷积核尺寸为96,个数为32 | 256×32 |
| 池化层1 | 池化块尺寸为4,个数为32 | 64×32 |
| 卷积层2 | 卷积核尺寸为33,个数为64 | 64×64 |
| 池化层2 | 池化块尺寸为4,个数为64 | 16×64 |
| 卷积层3 | 卷积核尺寸为4,个数为128 | 16×128 |
| 池化层3 | 池化块尺寸为4,个数为128 | 4×128 |
| 卷积层4 | 卷积核尺寸为4,个数为128 | 4×128 |
| 池化层4 | 池化块尺寸为4,个数为128 | 1×128 |
| 完全连接层 | 节点个数为128 | 128×1 |
| Softmax函数 | 节点个数为10 | 10 |

第1,2卷积层选用的宽卷积核能够削弱高频噪 声对提取有用特征时的影响,可起到抗干扰作 用^[16]。第1.2卷积内核大小分别为 1×96 和 1×33 . 步长分别为1×8和1×1,其余卷积内核大小为1× 4,步长为1×1。加噪训练样本在进入第1宽卷积核 提取短时特征之后,输出特征经过BN层处理后,被 迫呈标准正态分布,落入ReLU激活函数的敏感区 域。引入 Dropout 算法构建 Dropout 层以增强改进 ACNN训练时的干扰,从而强化改进ACNN的识别 能力,最后特征经过最大池化层完成特征的提取。 同时,在各个特征提取层中引入注意力机制,建立特 征提取通道之间的联系,增强对非敏感特征的提取 能力,在交替连接的卷积层和池化层间完成特征提 取的全过程。第4个池化层的输出作为 Dropout 层 的输入,将其输出作为全连接层的输入,全连接层的 神经元个数为128。提取好的特征经过FCL,BN, ReLU和Softmax函数层,输出损伤程度类型。

为了展示笔者提出方法的不断迭代与学习过程,基于 Python-Tensorflow 搭建改进的 ACNN 模型。图 3 为训练集与测试集识别正确率及损失值的变化情况。以 F₁数据集为例,笔者设置一次性参与

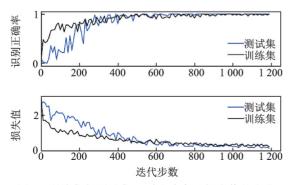


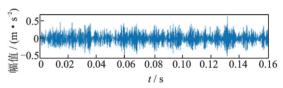
图 3 训练集与测试集识别准确率及损失值的变化

Fig.3 Accuracy and loss function of training set and testing set

计算的样本数量 batch=50,随着迭代步数的增加,训练集和测试集的正确率逐渐增大,说明模型在向正确的方向学习。当步数达到 600 时,模型在测试集的正确率略高于训练集,而损失值低于训练集。这表明模型没有发生过拟合现象,训练效果良好。

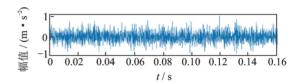
3.3 方法鲁棒性验证

本小节将通过试验来验证改进的 ACNN 模型具有较强的鲁棒性。实验 1 为模型的抗噪性试验。实验 2 为模型的领域自适应试验,即测试样本的分布与训练样本的分布不一致的情况。考虑到在实际应用中噪声对传感器测得的信号干扰,试验模拟工业噪声对测试样本的影响,信噪比(signal to noise ratio,简称 SNR)可以评价信号中所含噪声的多少。图 4 为滚珠原始振动信号和加噪信号的时域图。可见,加噪信号的幅值增大,干扰增强,原始故障信号被进一步湮没。



(a) 滚珠原始振动信号时域图

(a) Time domain diagram of the original vibration signal of the ball



(b) 滚珠加噪信号的时域图

(b) Time domain diagram of the signal of the ball with noise 图 4 滚珠原始振动信号和加噪信号的时域图

Fig.4 Time domain diagram of the original vibration signal and noise signal of the ball

为了显示笔者所提方法改进部分的优势,采用不同的试验方案进行验证。对比试验控制了4个变量,包括主模型、训练样本处理、卷积层Dropout算法的设置和注意力机制的设置。首先,主要模型包括传统CNN和ACNN,两者的结构参数相同,如表1所示;其次,训练样本处理的区别在于是否添加噪声;然后,是否在第1,4卷积层中引入Dropout算法;最后,是否在各个特征提取层中引入注意力机制。不同模型的变量设置如表2所示。

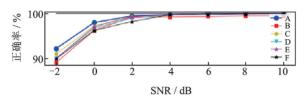
3.3.1 抗噪性试验

试验按比例 4:1 无交集的划分训练集和测试集,分别将数据集 F_1 , F_2 , F_3 输入到 6 个模型中进行训练,测试样本输入到各自训练好的模型中进行测试。不同模型在 3 个数据集上的识别结果如图 5 所示。

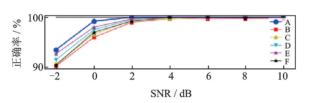
表 2 不同模型的变量设置

Tab.2 Variable settings for different models

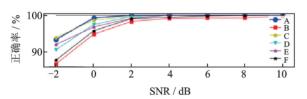
| 模型 一 | 变量设置 | | | | |
|------|------|------------------|--------|--|--|
| | AM | Dropout算法的设置 | 训练样本加噪 | | |
| A | 是 | 是(Dropout率为90%) | 是 | | |
| В | 是 | 是(Dropout率为80%) | 是 | | |
| С | 否 | 是(Dropout率为90%) | 否 | | |
| D | 否 | 否(Dropout率为100%) | 是 | | |
| Е | 否 | 是(Dropout率为90%) | 是 | | |
| F | 否 | 否(Dropout率为100%) | 否 | | |



- (a) 6个模型分别在数据集F,上的识别正确率
- (a) The recognition accuracy of the six models on the data set F_1



- (b) 6个模型分别在数据集F2上的识别正确率
- (b) The recognition accuracy of the six models on the data set F_2



- (c) 6个模型分别在数据集F,上的识别正确率
- (c) The recognition accuracy of the six models on the data set F_3 图 5 不同模型在 3个数据集上的识别结果

Fig.5 Recognition results of different models on three data sets

可见,当分别采用3种数据集进行训练和测试时,6个模型在SNR=-2dB高噪声环境下的识别率均达到85%。相比之下,模型A的平均识别正确率最高,达到93.0%,分别比模型B,C,D,E,F高出4.39%,1.15%,2.31%,1.47%和3.68%。随着SNR的增大,所有模型的正确率进一步提高,在4dB~10dB环境中达到100%的准确率。分别将模型C,D与F相比,模型A与B相比,发现在任意SNR下,模型C和D的正确率都高于模型F,模型A都要高于模型C和D的正确率都高于模型F,模型C比F高出7.51%,模型D比F高出3.27%;模型A比B高出25.64%。结果表明,在ACNN模型的卷积层中引

入Dropout算法,相当于给模型增加训练干扰,使模型在噪声中的表现更好,比未改进前的传统CNN更具抗噪能力。另外,加入噪声训练的方法能有效抑制模型的过拟合,使模型在噪声环境下的表现更优。同理,将模型E与D,F相比,模型E分别比D,F高出2.79%和6.06%,结果进一步表明卷积层中引入Dropout算法和加入噪声训练能提升模型的抗干扰能力。

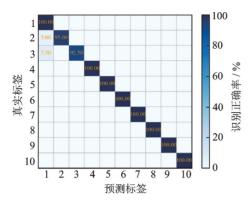
将模型A与模型C,D,E相比,无论在哪种噪声环境中,A模型的识别正确率始终高于其他3个模型。在-2dB~4dB强噪声环境中,模型A比模型C,D分别高出8.85%和13.09%,比E高出10.3%。结果表明,在各个特征提取层中引入注意力机制,可以对卷积后的表达重新加权以改善每个卷积层的输出,从而增强有用信息的权重,提高在噪声环境下提取特征的能力。

为进一步分析笔者提出方法对损伤类型及载荷的敏感性,表3为笔者方法在SNR=0dB环境中,3种负载工况下的10种轴承损伤类型的识别正确率。可见,所提方法对各损伤类别的识别率集中在100%,对3种载荷下的轴承损伤类型敏感性好,识别结果表现优异。

表 3 笔者方法对损伤类型的识别正确率

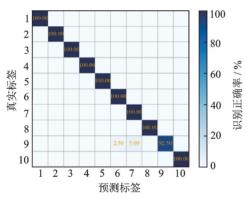
| 类型 | 尺寸/mm | 类别 | 负载/W | | |
|------|---------|----|--------|--------|--------|
| | | | 735 | 1 470 | 2 205 |
| 滚珠损伤 | 0.177 8 | 1 | 100.00 | 100.00 | 100.00 |
| | 0.355 6 | 2 | 95.00 | 100.00 | 97.50 |
| | 0.5334 | 3 | 92.50 | 100.00 | 100.00 |
| 内圈损伤 | 0.177 8 | 4 | 100.00 | 100.00 | 100.00 |
| | 0.355 6 | 5 | 100.00 | 100.00 | 97.50 |
| | 0.5334 | 6 | 100.00 | 100.00 | 100.00 |
| 外圈损伤 | 0.177 8 | 7 | 100.00 | 100.00 | 100.00 |
| | 0.355 6 | 8 | 100.00 | 100.00 | 100.00 |
| | 0.533 4 | 9 | 100.00 | 92.25 | 100.00 |
| 正常 | _ | 10 | 100.00 | 100.00 | 100.00 |

由于在3种负载工况下存在少量误分类的情况, 图 6 为所提方法的混淆矩阵正确率。分析 735 W 负载工况下 0.355 6 mm 和 0.533 4 mm 的滚珠损伤, 其 正 确 率 为 95.00% 和 92.50%,分别有 5% 的 0.355 6 mm 损伤样本和 7.5% 的 0.355 6 mm 损伤样 本被误识别为 0.177 8 mm 滚珠损伤。虽然损伤尺 寸不同,但在轴承出现损伤后,可以将损伤快速定位 到滚珠。同理,1 470 W 和 2 205 W 负载工况下的结



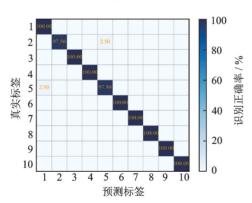
(a) 735 W工况下混淆矩阵图

(a) Confusion matrix diagram under 735 W condition



(b) 1470 W工况下混淆矩阵图

(b) Confusion matrix diagram under 1 470 W condition



(c) 2205 W工况下混淆矩阵图

(c) Confusion matrix diagram under 2 205 W condition

图 6 所提方法的混淆矩阵正确率

Fig.6 Confusion matrix of the proposed method with accuracy

果也是如此。

3.3.2 领域自适应试验

为验证改进的 ACNN 模型在噪声环境中的变工况下识别轴承损伤程度的能力,设置了领域自适应试验。训练模型时,本实验直接引入实验1训练得到的6个模型,并另外增加模型G来进一步验证所提出改进部分的优越性。G表示 ACNN 结构,每个特征提取层中引入注意力机制,但训练样本未加

噪,第1,4卷积层无 Dropout 算法。实验时,将剩余2个数据集分别进行测试,如 $F_1 \rightarrow F_2$ 表示利用数据集 F_1 中的1600个样本进行模型训练,利用数据集 F_2 中2000个样本用于模型测试。验证模型领域自适应能力的数据集设置如表4所示。

表 4 验证模型领域自适应能力的数据集设置
Tab.4 Data set to verify the model domain adaptive ability

| 编号 | 训练集 | 训练 样本数 | 测试集 | 测试 样本数 | SNR/ dB |
|-----|------------|-----------|----------------------------|-----------|-------------|
| 1 F | E | 1 600 | F_2 | 2 000 | -3~5 |
| | Γ_1 | 1 600 | F_3 | 2 000 | $-3\sim5$ |
| 2 | E | 1 600 | \overline{F}_1 | 2 000 | $-3\sim5$ |
| | F_2 | | F_3 | 2 000 | $-3 \sim 5$ |
| 3 | E | 1 600 | F_1 | 2 000 | -3~5 |
| | F_3 | | $F_{\scriptscriptstyle 2}$ | 2 000 | $-3\sim5$ |

为了证明所提出方法的优点,首先验证没有向测试集中加额外白噪声的跨负载实验,使用笔者所提方法、传统 CNN 和基于训练干扰卷积神经网络 (training interference convolutional neural networks,简称 TICNN)分析相同的数据集并进行比较。不同模型的识别正确率如表 5 所示。

表 5 不同模型的识别正确率

Tab.5 The recognition accuracy of different models %

| 14 14 14 11 | | 模型 | |
|-----------------------|--------|----------------------|-------|
| 试验类别 | 传统 CNN | TICNN ^[9] | 笔者方法 |
| $F_1 \rightarrow F_2$ | 99.22 | 99.50 | 100.0 |
| $F_1 \rightarrow F_3$ | 85.25 | 91.10 | 93.22 |
| $F_2 \rightarrow F_1$ | 95.50 | 97.60 | 96.23 |
| $F_2 \rightarrow F_3$ | 99.10 | 99.40 | 98.16 |
| $F_3 \rightarrow F_1$ | 94.20 | 90.20 | 93.71 |
| $F_3 \rightarrow F_2$ | 98.75 | 98.70 | 99.26 |
| 平均正确率 | 95.33 | 96.10 | 96.76 |

从表 5 可以看出,当验证 $F_2 \rightarrow F_3$ 和 $F_3 \rightarrow F_1$ 试验时,笔者方法稍逊于传统 CNN 方法。分析原因,为增强传统 CNN 方法的抗干扰能力,训练样本加噪和卷积层引入 Dropout 算法给网络增加了训练干扰,以提高模型的抗噪声能力。在跨负载测试时,传统 CNN 的平均识别正确率为 95.33%,基于 TICNN 方法的平均正确率为 96.10%,笔者方法的平均识别正确率达到 96.76%,相比其他方法的识别效果更好。另外,为验证所提改进方法在噪声环境下比传统 CNN 具有更强的领域自适应能力,在测试样本中加入信噪比为 $-3\sim5$ dB的噪声进行试验验证。

选用 t-随机邻近嵌入(t-distributed stochastic

neighbor embedding, 简称 t-SNE) 算法将所有卷积层与全连接层的特征表达降成2维分布,通过可视化改进的ACNN模型的训练过程来展示模型的特征提取过程。由于篇幅原因,图7为模型A在 F_1 负载下训练好的模型,在SNR=0dB环境中数据集 F_2 从每个卷积层通过t-SNE方法提取的测试样本特征分布图。由图7可以看出,随着特征提取层的深入,特征可分割性不断增强。特别是在通过第2卷积层之后,各类损伤特征点分布有了明显的分割效果,最终实现特征的有效分类。随着改进ACNN模型网络层数的增加,每一层的特征可分性越来越强,说明深度结构的必要性。从FCL可以看出,用 F_1 数据集训练出来的改进ACNN模型,在噪声环境下对 F_2 跨负载数据集有很好的损伤识别能力。

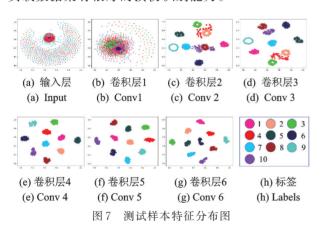


Fig.7 Feature distribution of test samples

为了测试改进的ACNN模型在噪声环境中变工况下轴承损伤程度的识别正确率,试验比较了模型A,C,D,E,F和G在SNR=0dB环境中的变负载测试集上的损伤识别正确率,结果如表6所示。

表 6 改进 ACNN 模型的损伤识别率

Tab.6 Damage recognition rate of improved ACNN model and comparison algorithm

| 类别 | 模型 | | | | | | |
|-----------------------|-------|-------|-------|-------|-------|-------|--|
| | A | С | D | Е | F | G | |
| $F_1 \rightarrow F_2$ | 99.10 | 97.83 | 97.25 | 95.75 | 97.25 | 97.26 | |
| $F_1 \rightarrow F_3$ | 95.06 | 92.17 | 92.13 | 90.08 | 89.15 | 91.75 | |
| $F_2 \rightarrow F_1$ | 96.25 | 92.00 | 93.91 | 95.25 | 88.22 | 95.38 | |
| $F_2 \rightarrow F_3$ | 98.52 | 97.33 | 96.08 | 97.16 | 93.25 | 95.99 | |
| $F_3 \rightarrow F_1$ | 87.50 | 86.67 | 83.33 | 81.26 | 82.53 | 85.25 | |
| $F_3 \rightarrow F_2$ | 91.25 | 95.08 | 91.58 | 92.31 | 91.50 | 91.78 | |
| 平均正确率 | 94.61 | 93.51 | 92.38 | 91.97 | 90.32 | 92.90 | |

由表 6 可以看出,对于在某一负载工况下训练样本,在噪声环境中跨负载进行样本测试。笔者提出的模型 F 在 SNR=0 dB 时的平均正确率为90.32%,而改进的 ACNN模型达到94.61%,并且是

所有模型中表现最好的。将模型 C, D, E和 F相比较,模型 C, D, E分别比 F高出 3.19%, 2.06%和1.65%。结果表明,在 ACNN模型的卷积层中引入Dropout算法和加入噪声训练的方法既可以提高模型的抗干扰能力,还能提高变负载工况下轴承损伤识别正确率,比未改进的传统 CNN表现更优。将模型 F和 G相比较,模型 G的平均正确率为92.90%,比 F高出 2.58%。同理,模型 A比 E高出 2.64%。可见,在各个特征提取层引入注意力机制,可有效改善每个特征提取层的输出,从而增强模型在噪声环境下的跨负载自适应能力。

表7为改进ACNN模型及传统CNN在SNR=-3~5dB环境下的损伤识别率。

表 7 改进 ACNN 模型及传统 CNN 的损伤识别率 Tab.7 Damage recognition rate of improved ACNN model

and traditional CNN

平均 SNR/dB 类别 模型 -3正确率 76.75 97.27 99.76 100.0 100.0 Α 94.76 $F_1 \rightarrow F_2$ F 83.10 96.25 99.00 99.52 99.24 95.42 76.26 94.51 96.26 96.00 96.24 91.85 Α $F_1 \rightarrow F_2$ F 77.76 87.73 89.72 88.00 87.50 86.14 83.50 94.50 97.26 98.25 98.25 94.35 Α $F_2 \rightarrow F_1$ F 78.52 85.50 92.55 95.78 97.00 89.87 86.50 94.74 98.23 98.50 98.75 95.34 $F_2 \rightarrow F_3$ F 82.75 89.50 96.20 98.50 99.25 93.24 Α 73.10 84.78 88.52 91.00 92.75 86.03 $F_3 \rightarrow F_1$ F 66.25 79.76 86.53 89.00 90.50 82.41 97.00 98.25 90.21 75.78 86.50 93.51 Α $F_3 \rightarrow F_2$ F 68.00 89.25 95.76 97.25 97.50 89.55 平均 Α 78.65 92.05 95.59 96.79 97.37 92.09 正确率 76.06 87.99 93.29 94.68 95.17 89.44

无论采用何种工况下的样本训练模型,在SNR=-3~5 dB 环境中进行跨负载样本测试,改进的ACNN模型法的识别正确率始终高于传统CNN。改进的ACNN模型的平均识别正确率为92.09%,比传统CNN的89.44%高出2.65%。可见,笔者提出的改进ACNN模型提升了传统CNN的抗噪声和变负载自适应能力。

4 结 论

1)提出了一种新的解决噪声环境和变负载工况下轴承损伤识别问题的改进 ACNN模型。改进的 ACNN模型可直接训练通过数据增强技术处理得到的标签化加噪样本,无需任何振动信号的预处

理过程。对于美国凯斯西储大学轴承数据库,在信噪比为0dB时,平均识别率为98.83%;在信噪比为-3~5dB时,变负载工况下的平均识别率达到92.09%。

2) 改进的 ACNN 模型有 2个主要的抗干扰结构,即训练样本加噪和卷积层引入 Dropout 算法。网络中对卷积层引入 Dropout 算法得到的模型相比其他模型对噪声的容忍度更高,所提出的训练样本加噪的方法能有效防止神经网络的过拟合。采用第1,2宽卷积核可以在高频噪声下提取有用特征。每个特征提取层输出端引入注意力机制可以改善卷积层的输出,通过对池化层降采样操作后的表达重新加权,以提高变负载复杂特征的提取能力。试验结果表明,改进的 ACNN 模型相比其他模型对噪声和变负载工况下的轴承损伤信号的识别正确率更高。

参 考 文 献

- [1] ZHANG Z W, CHEN H H, LI S M, et al. A novel geodesic flow kernel based domain adaptation approach for intelligent fault diagnosis under varying working condition[J]. Neurocomputing, 2019,376:54-64.
- [2] OJAGHI M, YAZDANDOOST N. Oil-whirl fault modeling, simulation, and detection in sleeve bearings of squirrel cage induction motors[J]. IEEE Transactions on Energy Conversion, 2015, 30(4): 1537-1545.
- [3] HAO S J, GE F X, LI Y M, et al. Multisensor bearing fault diagnosis based on one-dimensional convolutional long short-term memory networks [J]. Measurement, 2020, 159: 107802.
- [4] LI Y B, YANG Y T, WANG X Z, et al. Early fault diagnosis of rolling bearings based on hierarchical symbol dynamic entropy and binary tree support vector machine [J]. Journal of Sound and Vibration, 2018, 428 · 72-86
- [5] 戴洪德,陈强强,戴邵武,等.基于样本分位数排列熵的故障诊断方法[J].振动与冲击,2019,38(23):152-156,170.
 - DAI Hongde, CHEN Qiangqiang, DAI Shaowu, et al. Fault diagnosis method based on sample quantile permutation entropy [J]. Vibration and Shock, 2019, 38(23): 152-156, 170. (in Chinese)
- [6] HARMOUCHE J, DELPHA C, DIALLO D. Improved fault diagnosis of ball bearings based on the global spectrum of vibration signals [J]. IEEE Transactions on Energy Conversion, 2015, 30(1): 376-383.
- [7] 孙文珺,邵思羽,严如强.基于稀疏自动编码深度神经 网络的感应电动机故障诊断[J].机械工程学报,2016,52(9):65-71.
 - SUN Wenjun, SHAO Siyu, YAN Ruqiang. Induction motor fault diagnosis based on deep neural network of sparse auto-encoder[J]. Journal of Mechanical Engineering, 2016, 52(9):65-71. (in Chinese)

- [8] JANSSENS O, SLAVKOVIKJ V, VERIVSCH B, et al. Convolutional neural network based fault detection for rotating machinery [J]. Journal of Sound and Vibration, 2016, 377: 331-345.
- [9] 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.
- [10] 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 Bo, TIAN Fuqing, LIANG Weige. Fault diagnosis method based on deep convolution variational self-encoding network [J]. Journal of Instrumentation, 2018, 39(10):27-35. (in Chinese)
- [11] JIA F, LEI Y G, LU N, et al. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization[J]. Mechanical Systems and Signal Processing, 2018,110: 349-367.
- [12] ZHAO M H, ZHONG S S, FU X Y, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020, 16(7):4681-4690.
- [13] LI X, ZHANG W, DING Q. Understanding and improving deep learning-based rolling bearing fault diagnosis with attention mechanism[J]. Signal Processing, 2019,161:136-154.
- [14] 李艺伟. 基于改进 CNN 的变工况下滚动轴承故障诊断 方法研究[D]. 哈尔滨:哈尔滨理工大学,2019.
- [15] DONG S J, WU W L, HE K, et al. Rolling bearing performance degradation assessment based on improved convolutional neural network with anti-interference [J]. Measurement, 2020, 151: 107219.
- [16] GAN M, WANG C, ZHU C A. Construction of hierarchical diagnosis network based on deep learning and its application in the fault pattern recognition of rolling element bearings [J]. Mechanical Systems and Signal Processing, 2016(72/73): 92-104.



第一作者简介:董绍江,男,1982年12月生,博士、教授、博士生导师。主要研究方向为机械故障诊断和机电一体化技术。曾发表《Rolling bearing performance degradation assessment based on improved convolutional neural network with anti-interference》(《Measurement》2020, Vol.151)等论文。

E-mail:dongshaojiang100@163.com

通信作者简介: 裴雪武, 男, 1995年3月生, 硕士生。主要研究方向为机械故障诊断。

E-mail: 398721763@qq.com