

改进 1DCNN 与相似性度量增强的齿轮箱故障识别

熊 焘¹, 郑少帅^{1,2}, 何 俊³, 杨世锡³

(1. 上海大学机电工程与自动化学院 上海, 200444) (2. 上海航天控制技术研究所 上海, 201109)

(3. 浙江大学机械工程学院 杭州, 310027)

摘要 齿轮箱发生故障时, 因振源耦合等因素, 各类单一故障和复合故障间具有一定共性特征, 造成传统的基于卷积神经网络(convolutional neural network, 简称 CNN)的智能诊断方法准确率下降和诊断性能鲁棒性差。针对上述问题, 提出一种新的基于一维卷积神经网络(one-dimensional CNN, 简称 1DCNN)的齿轮箱故障智能识别方法。该网络引入 LeakyRelu 激活函数替代原网络结构卷积层中的激活函数, 防止训练时的神经元失效; 利用 LookAhead 优化器, 避免反向参数优化时训练结果收敛于局部极值; 提出相似性损失度量函数, 最小化同类样本序列间距的同时最大化不同类样本序列间距, 以强化网络结构的标签识别能力和分类稳定性。将上述网络命名为 sLL-1DCNN, 利用齿轮箱故障模拟试验台信号对网络进行训练并识别各类故障, 结果表明, 该网络在训练集样本序列数量较少时具有更好的特征提取和泛化能力, 且在训练集样本序列数量增加时, 具备优于其他 3 种 CNN 的分类能力和分类稳定性。

关键词 齿轮箱; 多工况; 复合故障; 卷积神经网络; 相似度矩阵

中图分类号 TH133.3; TH17

引 言

齿轮箱在机械设备中起着连接和传递动力的作用, 通常工作于变转速、变载荷的工况条件下。由于结构复杂, 系统中零部件间的振动耦合和激励的不确定性变强^[1]。此外, 齿轮啮合时存在齿侧间隙、重合度时变等非线性因素, 这些因素共同作用, 导致振动加剧, 诱发齿轮、轴承等零部件故障, 且复合故障信号具有较强共性特征, 使诊断变得困难。

针对上述问题, 科研人员以机器学习和统计推断为主要手段, 展开了广泛深入的研究。He 等^[2]利用多传感器采集到的齿轮箱信号进行多域特征信息融合, 并利用神经网络区分故障状态, 取得了良好的效果。Wang 等^[3]提出一种基于并行双参数优化共振算法的稀疏信号分解方法, 通过多点优化最小熵解卷, 实现齿轮箱复合故障的识别。李状等^[4]以相对小波包能量作为风电机组齿轮箱振动信号的特征值, 采用粒子群优化的模糊核聚类算法对特征信号进行分类。以上工作由于存在参数及特征选择的不确定性, 使得诊断结果也具有一定的不确定性^[5]。

近年来, 深度学习技术的发展使人们开始关注其在机械故障诊断领域的应用, 相关应用包括长短时记忆神经网络^[6]、循环神经网络^[7]和卷积神经网络^[8]等。文献[9-10]综合分析了各类深度学习网络结构在故障诊断领域的适用性, 指出一维卷积神经网络能够有效实现故障特征信息的自提取。Qiu 等^[11]采用 1DCNN 对齿轮单一故障进行了诊断, 但研究并未涉及齿轮轴承复合故障的诊断问题。Wang 等^[12]提出多注意力 1DCNN 算法用于滚动轴承故障识别, 并通过方法横向比较, 验证了所提方法的优越性。胡葛庆等^[13]等将经验模式分解(empirical mode decomposition, 简称 EMD)与 1DCNN 相结合, 将 EMD 所得的固有模式函数进行信息融合以自动提取特征, 但该方法的有效性只在行星齿轮箱的单一故障信号上得到了验证。通过文献梳理, 笔者拟将 1DCNN 作为特征学习与分类的基本网络结构, 用于多工况下齿轮、轴承单一和复合故障的诊断问题。在基本网络结构基础上, 引入 LeakyRelu 激活函数^[14]和 LookAhead 优化器^[15], 以构建改进的 1DCNN。此外, 引入相似性损失度量函数, 最终在

* 国家重点研发计划资助项目(2020YFB1709902); 国家自然科学基金资助项目(51705302); 上海市“科技创新行动计划”专项资助项目(21SQBS01400)

收稿日期: 2020-00-00; 修回日期: 2020-00-00

考虑该度量函数的基础上提出一种新的 sLL-1DCNN 网络,加强网络对同类特征的聚类,提高特征提取能力。

1 改进的 1DCNN 方法

假设关于原始信号的时间序列样本集合为 $X = \{x^{(1)}, \dots, x^{(i)}, \dots, x^{(n)}\}$, $1 \leq i \leq n$, 其中: $x^{(i)}$ 为 m 维样本序列; n 为样本序列的个数。

1) 对样本序列进行归一化

$$\bar{x}_j^{(i)} = \frac{x_j^{(i)} - \min(X_j)}{\max(X_j) - \min(X_j)} \quad (1)$$

其中: $x_j^{(i)}$ 为 $x^{(i)}$ 的第 j 个元素 ($1 \leq j \leq m$); $\max(X_j)$ 和 $\min(X_j)$ 分别为样本集合 X 第 j 行元素中的最大值和最小值; $\bar{x}_j^{(i)}$ 为 $x_j^{(i)}$ 的归一化结果; \bar{X} 为由 $\bar{x}_j^{(i)}$ 构成的归一化样本集合。

2) 卷积层的运算为

$$C_k = f \left[a_k + \sum_{z=1}^Z \text{conv1D}(w_k, C_{k-1}^z) \right] \quad (2)$$

其中: w_k 为第 k 个卷积层的卷积核 ($1 \leq k \leq K$); a_k 为该层的偏置向量; Z 为卷积运算的次数; C_{k-1} 为第 k 个卷积层的输入 (也表示第 $k-1$ 个池化层的输出); C_{k-1}^z 的上标 z 表示 C_{k-1} 作为第 k 个卷积层的输入在该层中进行的第 z 次卷积运算; C_k 为第 k 个卷积层的输出。

当 $k=1$ 时, 第 1 个卷积层的输入 $C_0 = \bar{X}_{n_1}, \bar{X}_{n_1}$ 为包含 n_1 ($n_1 \leq n$) 个批处理样本序列的归一化子样本集合。

$f(*)$ 表示将卷积运算结果做非线性映射的激活函数。工程中常用的激活函数有很多种^[8], 其中 Relu 函数因运算简单、收敛速度快, 在很多场合中被使用^[11]。由式 (3) 可知, 一旦出现 $* < 0$ 的情况, $f_{\text{Relu}}(*) = 0$, 神经元的功能便失效了, 激活函数因此也无法收敛。为了避免该问题的发生, 笔者引入 LeakyRelu 激活函数, 保证 $* < 0$ 时的 $f_{\text{LeakyRelu}}(*)$ 有非零取值, 避免了激活函数不收敛的情况。

$$\begin{cases} \text{Relu:} & f_{\text{Relu}} = \max(0, *) \\ \text{LeakyRelu:} & f_{\text{LeakyRelu}} = \max(0.01 \cdot *, *) \end{cases} \quad (3)$$

3) 池化层提取子区域最大特征的算法为

$$O_k = \max \{ C_k^{[(d, l) \Rightarrow (d, l+1)]} \} \quad (4)$$

其中: d 为池化长度; l 为步长 (子区域由 d 和 l 共同定义); $C_k^{[(d, l) \Rightarrow (d, l+1)]}$ 表示 C_k 从子区域 (d, l) 到 $(d, l+1)$ 的池化输入过程; O_k 为第 k 个池化层的

输出。

4) 将特征 O_k 输入至全连接层, 按列排列成抽象特征矩阵 R_s 。利用式 (5) 中的 Softmax 函数, 计算样本序列 $x^{(i)}$ 可能归属于标签 $y^{(i)}$ 的隶属度

$$h(x^{(i)}) = \frac{1}{\sum_{s=1}^N e^{(U_s^T R_s^{(i)} + b_s)}} \begin{bmatrix} e^{(U_1^T R_s^{(i)} + b_1)} \\ \vdots \\ e^{(U_s^T R_s^{(i)} + b_s)} \\ \vdots \\ e^{(U_N^T R_s^{(i)} + b_N)} \end{bmatrix} \quad (5)$$

其中: U_s 为分类层中与第 s 个神经元相连的权值向量; b_s 为该神经元的偏置; $R_s^{(i)}$ 表示从样本序列 $x^{(i)}$ 中提取的特征, 即矩阵 R_s 的列向量。

5) 利用梯度下降算法最小化交叉熵损失函数

$$L_1 = -\frac{1}{n_1} \left[\sum_{i=1}^{n_1} \sum_{s=1}^N \{ y^{(i)} = s \} \lg \frac{e^{(U_s^T R_s^{(i)} + b_s)}}{\sum_{s=1}^N e^{(U_s^T R_s^{(i)} + b_s)}} \right] \quad (6)$$

其中: $\{ \cdot \}$ 为指示函数, 当 \cdot 为真时, $\{ \cdot \} = 1$; 否则 $\{ \cdot \} = 0$ 。

由于常用的网络参数优化器 Adam 易收敛于局部极值^[14], 因此引入包含内、外双循环的改进 LookAhead 优化器。外循环参数 $\omega \in \{ w_k, a_k, U_s, b_s \}$ 为待更新网络参数; 内循环则仍利用 Adam 优化参数 φ , 并利用线性插值更新 ω 。优化器中预定义的参数包括内、外循环迭代次数 q 和 p , ω 初值 ω_0 、损失函数 L_1 、学习率 α 和 Adam 优化器 opt。伪代码如下:

```

for p = 1, 2, ..., do
    赋值  $\varphi_{p,0} \leftarrow \omega_{p-1}$ 
    for q = 1, 2, ..., do
        从  $\bar{X}$  中随机采样  $\bar{X}_{n_1}$ 
         $\varphi_{p,q} \leftarrow \omega_{p,q-1} + \text{opt}(L_1, \omega_{p,q-1}, \bar{X}_{n_1})$ 
    end for
    更新  $\omega_p \leftarrow \omega_{p-1} + \alpha(\varphi_{p,q} - \omega_{p-1})$ 
end for
return  $\omega$ 
    
```

2 相似性损失学习方法

网络优化的目标是使从同一类样本序列中提取的特征尽可能相似, 而从不同类样本序列提取的特征尽可能差异大。特征间的相似性用核函数度量^[16]。笔者选取高斯函数作为核函数, 按照式 (7) 计算相似度矩阵 P 的元素

$$P_{uv} = \exp\left(-\frac{\|g(R_s^u) - g(R_s^v)\|_2^2}{\sigma}\right) \quad (7)$$

其中: $g(\cdot)$ 为高斯核函数; σ 为带宽。

由于每个样本序列包含 m 个样本点, 而经过卷积、池化运算后的是 m_1 个特征 ($m_1 < m$), 因此上述运算是一个降维过程。 R_s^u 和 R_s^v 表示从 \bar{X}_{n_1} 的样本序列 $\bar{x}_{n_1}^{(u)}$ 和 $\bar{x}_{n_1}^{(v)}$ 中提取到的 m_1 维特征向量, 其中 $(u, v) \in \{1, 2, \dots, n_1\}$ 。然后, 根据式(8)求解相似性损失函数

$$L_2 = \frac{1}{2\|Q\|_1} \sum_{u=1}^{n_1} \sum_{v=1}^{n_1} Q_{uv} (P_{uv} - A_{uv})^2 \quad (8)$$

其中: Q_{uv} 为矩阵 Q 的元素; $\|Q\|_1 = \sum_{u=1}^{n_1} \sum_{v=1}^{n_1} |Q_{uv}|$ 。

为使同类样本序列特征尽可能相似的约束条件与不同类样本序列特征差异尽可能大的约束条件具有同等重要性, 令

$$Q_{uv} = \begin{cases} 1 & (u = v) \\ \frac{1}{N-1} & (u \neq v) \end{cases} \quad (9)$$

式(8)中的 A_{uv} 为理想相似度矩阵 A 的元素

$$A_{uv} = \begin{cases} a & (u = v) \\ b & (u \neq v) \end{cases} \quad (10)$$

其中: a 为属于同类标签的样本序列间的相似性测度, $0 < a < 1$; b 为属于不同类标签的样本序列间的差异性测度, $0 < b < 1$ 。

由于从同类样本序列中提取的特征向量间存在一定差异, 因此 a 取 0.9, 0.8 或 0.7; 从不同类样本序列中提取的特征向量间仍存在一定的相似性, 因此 b 取 0.1, 0.2 或 0.3。

引入新的相似性损失度量函数 L_2 后, 定义网络的损失函数 L 为

$$L = L_1 + L_2 \quad (11)$$

综上所述, 本研究在基于 LeakyRelu 激活函数和 LookAhead 优化器的改进 1DCNN 之上, 结合新提出的相似性损失函数, 构建特征学习能力更强的 sLL-1DCNN 网络, 其算法流程如图 1 所示。

3 试验验证

利用图 2(a, b) 所示的齿轮箱故障模拟试验台进行齿轮、轴承单一和复合故障的模拟试验。齿轮轴的输入、输出端均由图 2(c, d) 所示的圆锥滚子轴承支承。调整制动器电流可模拟不同大小的系统负载。如图 2(a) 所示, 在输入、输出端箱体上各安装

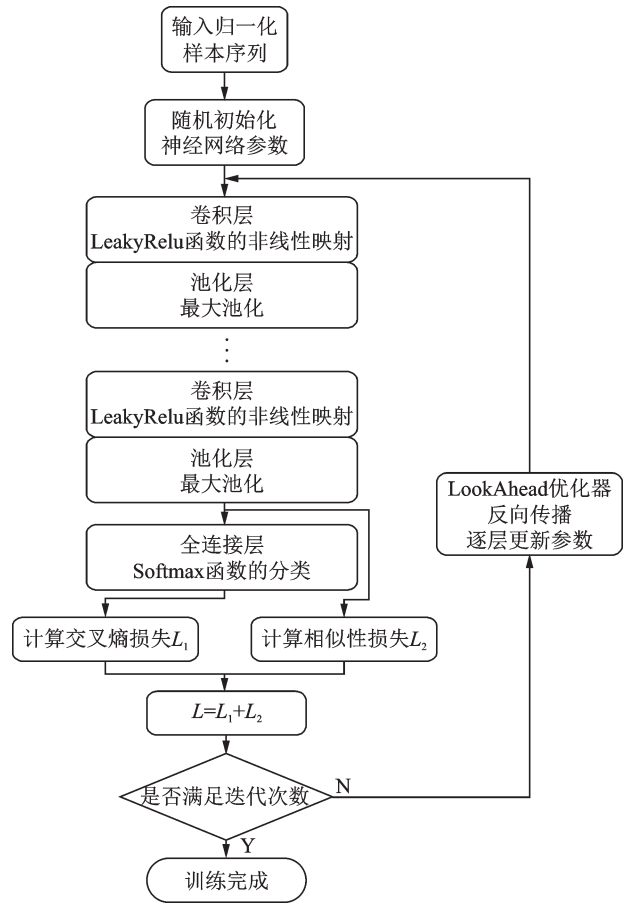


图 1 sLL-1DCNN 算法流程图

Fig.1 Flow chart of the sLL-1DCNN algorithm




图 2 齿轮箱故障模拟试验

Fig.2 Experiments of simulated gearbox faults

一枚加速度传感器。

试验分别在 7 个转速下进行, 每个转速分空载和带载两个工况, 如表 1 所示。试验模拟了 5 种齿轮箱状态, 因此样本序列标签数 $N=5$ 。其中: $s=1$ 为正常状态; $s=2$ 为输出轴齿轮齿根裂纹; $s=3$ 为输出轴齿根裂纹/输出轴输入端轴承外圈损伤的复合故障; $s=4$ 为输出轴齿根裂纹/中间轴输入端轴承内圈损伤; $s=5$ 为中间轴齿根裂纹。样本序列的划

分规则为:每类标签均包含 7 个转速下的空载和带载加速度信号,即包含 14 种不同工况的加速度信号,5 种标签则包含 70 组加速度信号,每组信号的采样时长为 15 s。将每组信号不重叠地依次拆分为 30 个样本序列,即可得到每类标签下的 420(30×14) 个样本序列,而 5 种标签将形成 2 100 个样本序列。在保证训练、验证和测试集均包含 5 种标签和 14 种工况的前提下,从样本序列中随机抽取各类标签下的样本序列,得到训练、验证和测试用样本序列集合。

表 1 试验参数

Tab.1 Experimental parameters

参数	取值
输入轴轴承型号	32205
中间轴轴承型号	32207
输出轴轴承型号	32211
输入轴齿轮齿数	20
中间轴齿轮齿数	49/19
输出轴齿轮齿数	60
载荷等级/(N·m)	0/2
转速等级/Hz	22/25/28/31/33/35/37
加速度传感器型号	PCB M608A11
采集卡型号	NI 9234
采样频率/kHz	25.6
单状态采样时长/s	15

由于试验台加速度信号高频噪声干扰大,考虑到卷积核可有效抑制高频噪声,所以采用的 sLL-1DCNN 在第 1 个卷积层有较大的卷积核。为了加快网络特征提取速度,从第 2 层开始均采用较小的卷积核^[8-9]。图 3 中的蓝色折线表示卷积层数不同时,sLL-1DCNN 在 10 次测试集分类后的平均准确率,横坐标 1~6 表示卷积层数。由图可知:当卷积层数小于 3 时,网络分类准确率很低;当卷积层数增加至 4 时,分类准确率提高到 90% 以上;当卷积层数为 5 时,分类准确率已稳定在 98% 以上。因此,sLL-1DCNN 的卷积层数定为 5。

图 3 中的红色折线表示卷积层数为 5 时,各层包含不同卷积核个数组合时的测试集分类准确率。横坐标 1~6 分别表示各层卷积核个数组合为 16-16-16-16,16-16-32-32-32,16-16-32-32-64,16-32-64-64-64,16-64-64-64-64 和 64-64-64-64-64。由图可知,当卷积核个数为 16-32-64-64-64(横坐标为 4) 时,获得最高分类准确率。综合参数分析结果,将试验数据分析时的 sLL-1DCNN 的详细参数列于表 2




图 3 不同卷积层数/卷积核组合对测试集分类结果的影响

Fig.3 Test sets classification results under different number of convolution level and kernel combination

表 2 网络结构参数

Tab.2 Network parameters

层名	参数	输出特征
输入层	一维加速度样本序列	1×12 800
卷积层 1	16 个 64×1 的卷积核,步长为 16	16×800
池化层 1	池化长度为 2,步长为 2	16×400
卷积层 2	32 个 3×1 的卷积核,步长为 3	32×134
池化层 2	池化长度为 2,步长为 2	32×67
卷积层 3	64 个 3×1 的卷积核,步长为 2	64×34
池化层 3	池化长度为 2,步长为 2	64×17
卷积层 4	64 个 3×1 的卷积核,步长为 1	64×17
池化层 4	池化长度为 2,步长为 2	64×8
卷积层 5	16 个 3×1 的卷积核,步长为 1	64×6
池化层 5	池化长度为 2,步长为 2	64×3
全连接层	192 个神经元	192
分类层	5 个神经元	5

中,带宽 $\sigma = 10^{[14]}$ 。

相似性损失函数中相似度矩阵元素 a 和 b 的取值如表 3 所示。为了消除小样本误差的影响,网络在各种 (a, b) 取值条件下均训练 10 次。然后用训练好的网络对测试集进行分类,得到 10 次分类的平均准确率。其中, $a = 0.9$ 与 $b = 0.1$ 时结果最优,所以 sLL-1DCNN 相似度矩阵中 $a = 0.9, b = 0.1$ 。

表 3 (a, b) 取值对测试集分类结果的影响

Tab.3 Effects of (a, b) on classification results %

参数	$a=0.6$	$a=0.7$	$a=0.8$	$a=0.9$
$b=0.1$	98.40	98.30	98.55	98.97
$b=0.2$	98.35	98.26	98.35	98.57
$b=0.3$	98.23	98.21	98.23	98.75
$b=0.4$	97.90	97.95	98.22	98.40

考虑学习率 α 对测试集分类结果的影响,若 α 取值过小,网络参数更新速度过慢^[6]。分析不同 α 取值下的分类结果,得到如图 4 所示的测试集分类准确率。当 α 增大到 0.018 时,分类准确率出现显著下降,因此取 $\alpha = 0.01$ 。同时发现,sLL-1DCNN 迭代 50 次已经收敛,因此令 $p = 50$ 。




图 4 不同学习率 α 对测试集分类结果的影响

Fig.4 Test sets classification under different learning rates α

图 5 为批处理个数取不同值时的测试集分类准确率。当批处理个数较少时,网络参数更新过快,模型难收敛。随着批处理个数的增加,网络分类能力逐渐提升。根据图 5 的结果,将批处理个数定为 20。




图 5 不同批处理个数对测试集分类结果的影响

Fig.5 Test sets classification under different batch numbers

下面分析激活函数、优化器的选取及相似性损失度量函数的引入对测试集分类结果的影响。图 6 为训练集样本序列数量不同时,1DCNN(ReLu+Adam),1DCNN(LeakyRelu+Adam),1DCNN(LeakyRelu+LookAhead)和 sLL-1DCNN 在 10 次测试集分类后的平均准确率。当训练样本序列数量为 210 时,1DCNN(LeakyRelu+LookAhead)的分类准确

率为 78.85%,比 1DCNN(LeakyRelu+Adam)的 80.58% 要低,表明 LookAhead 优化器在训练样本序列数量较少时性能比 Adam 优化器略差;而 1DCNN(ReLu+Adam)77.81% 的分类准确率要比 1DCNN(LeakyRelu+Adam)的 80.58% 低,表明 LeakyRelu 激活函数性能优于 ReLu 激活函数。另一方面,sLL-1DCNN 的分类准确率为 88.21%,表明与其他网络相比,sLL-1DCNN 在训练样本序列数量少的条件下具有更好的泛化能力。随着训练样本序列数量的增加,LookAhead 优化器的表现逐渐优于 Adam 优化器,而 LeakyRelu 激活函数的表现始终优于 ReLu 激活函数。当训练样本数量增加到 630 时,sLL-1DCNN 的分类准确率达到 97.93%。样本数量继续增加到 1 260 时,sLL-1DCNN 分类准确率达到 98.82%,准确率偏差仅为 0.53%。由此可知,sLL-1DCNN 在迭代相同次数后收敛于更高准确率,其分类能力优于其他 3 种网络。

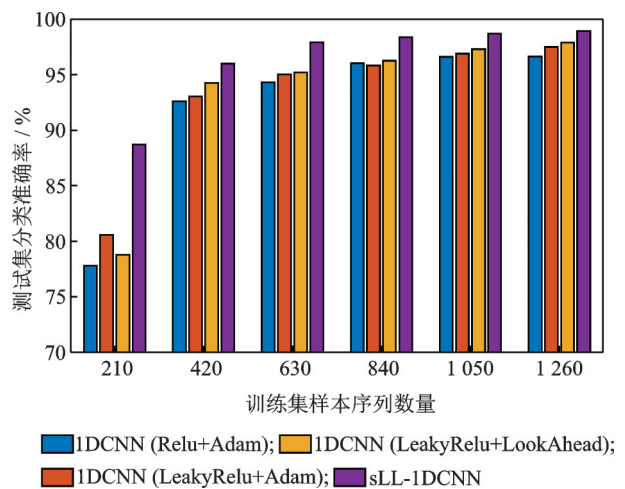


图 6 不同训练样本序列数量对测试集分类结果的影响

Fig.6 Test sets classification under different number of training sample series

当训练集样本序列数量为 1 260 时,将 4 种训练好的网络对同一测试集进行分类,分别得到相应的混淆矩阵,结果如图 7 所示,其中混淆矩阵的行表示预测的样本标签,列表示样本的真实标签。其中: $s=1$ 为正常状态; $s=2$ 和 $s=5$ 为单一故障状态; $s=3$ 和 $s=4$ 为复合故障状态。由图 7(a)可知,基于 1DCNN(ReLu+Adam)的网络进行测试集分类时,仅有 2 个真实标签为 $s=2$ 的样本被误分类,说明传统 1DCNN 能够有效识别齿轮箱的单一故障。当出现齿轮轴承复合故障,即 $s=3$ 和 $s=4$ 时,共有 5 个真实标签为 $s=3$ 样本序列被误分类,对 $s=3$ 样本的分

类准确率仅为 94.57%。有 7 个真实标签为 $s=4$ 样本序列被误分类,对 $s=4$ 样本的分类准确率为 90.67%。因此,1DCNN(ReLu+Adam)对复合故障的分类能力有限。由图 7(b, c)可知,其他两种 1DCNN 结构对复合和单一故障的误分现象越来越少,分类能力较 1DCNN(ReLu+Adam)有所改善。根据图 7(d)的分类结果,在 sLL-1DCNN 中,仅有 1 个真实标签为 $s=3$ 的样本被误分类,对 $s=3$ 样本的分类准确率达到 98.9%,而对真实标签为 $s=4$ 的样本分类准确率为 100%。因此,sLL-1DCNN 对不同工况下复合故障的识别能力最强。

将基于 sLL-1DCNN 的识别方法与基于 CNNS^[5] 和短时傅里叶变换(short-time Fourier transform,简称 STFT)+DCNN^[17] 两种方法的分类结果进行了对比,结果如表 4 所示。其中,精确率表示所预测样本序列标签实际为该标签的概率,而召回率表示实际属于某一标签的样本序列被预测为该标签的概率。为使分类结果具有客观性,表 4 所示结果均为 10 次分类结果的平均值。由表可知,sLL-

1DCNN 的分类精确率和召回率最高,且分类结果波动小,稳定性高,对齿轮箱不同故障状态的分类识别能力最强。

4 结束语

考虑到齿轮箱单一、复合故障信号具有较强共性特征的实际情况,提出了一种新的 sLL-1DCNN 网络,用于多工况条件下齿轮箱的故障识别。试验数据分析结果表明:引入 LeakyRelu 激活函数和 LookAhead 优化器构建而成的改进 1DCNN,在训练样本达到一定数量后,能够提高齿轮箱中包含复合故障在内的各类故障的分类准确率。在改进 1DCNN 结构中引入与交叉熵损失函数并行的相似性损伤函数后,构建了新的 sLL-1DCNN 网络。该网络可在训练样本序列数量较少时,准确识别多工况下的样本标签。随着训练样本序列数量的增加,故障识别的准确性更高,鲁棒性更强,且该网络的故障识别能力优于 CNNS 和 STFT+DCNN。

参 考 文 献

[1] ZHANG M, WANG K S, WEI D D, et al. Amplitudes of characteristic frequencies for fault diagnosis of planetary gearbox[J]. Journal of Sound and Vibration, 2018, 432: 119-132.

[2] HE J, YANG S X, PAPTHEOU E, et al. Investigation of a multi-sensor data fusion technique for the fault diagnosis of gearboxes[J]. Proceedings of the Institution of Mechanical Engineers Part C, Journal of Mechanical Engineering Science, 2019, 233 (13) : 4764-4775.

[3] WANG C G, LI H K, YOU J Y, et al. Identification of planetary gearbox weak compound fault based on parallel dual-parameter optimized resonance sparse decomposition and improved MOMEDA [J]. Measurement, 2020, 165: 108079.

[4] 李状,柳亦兵,滕伟,等.基于粒子群优化 KFCM 的风电齿轮箱故障诊断[J]. 振动、测试与诊断, 2018, 38(5): 484-488.

LI Zhuang, LIU Yibing, TENG Wei, et al. Fault diagnosis of wind turbine gearbox based on KFCM optimized by particle swarm optimization [J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(5): 484-488.(in Chinese)

[5] TURKER I, SERKAN K, LEVENT E, et al. Real-time motor fault detection by 1-D convolutional neural

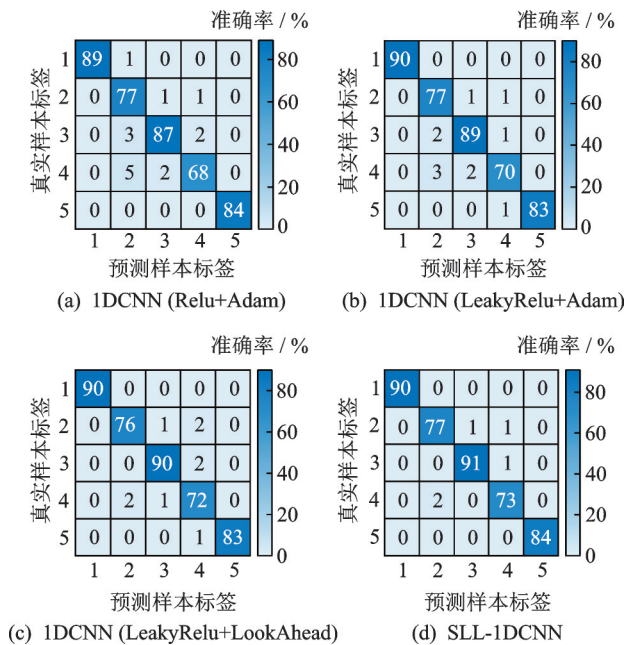


图 7 混淆矩阵比较

Fig.7 Comparisons of confusion matrices

表 4 分类结果对比

Tab.4 Comparisons of classification results %

方法	精确率	召回率
CNNS	93.29±1.37	93.32±1.42
STFT+DCNN	96.26±0.92	96.63±1.21
sLL-1DCNN	99.13±0.43	98.85±0.47

- networks [J]. IEEE Transactions on Industrial Electronics, 2016, 63(11): 7067-7075.
- [6] 李锋, 陈勇, 汤宝平, 等. 强化学习长短时记忆神经网络用于状态预测[J]. 振动、测试与诊断, 2020, 40(5): 895-903.
LI Feng, CHEN Yong, TANG Baoping, et al. Reinforcement learning long and short time memory neural network for state prediction [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(5): 895-903.(in Chinese)
- [7] YOU G W, PARK S. Diagnosis of electric vehicle batteries using recurrent neural networks [J]. IEEE Transactions on Industrial Electronics, 2017, 64(6): 4885-4893.
- [8] SENANNAVAKA J S L, KHANG H V, ROBBERSMY K G. Multiple classifiers and data fusion for robust diagnosis of gearbox mixed faults[J]. IEEE Transactions on Industrial Informatics, 2019, 15(8): 4569-4579.
- [9] 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.
- [10] GUO L, LEI Y G, XING S B, et al. Deep convolutional transfer learning network: A new method for intelligent fault diagnosis of machines with unlabeled data[J]. IEEE Transactions on Industrial Electronics, 2019, 66: 7316-7325.
- [11] QIU G Q, GU Y K, CAI Q. A deep convolutional neural networks model for intelligent fault diagnosis of a gearbox under different operational conditions [J]. Measurement, 2019, 145: 94-107.
- [12] WANG H, LIU Z, PENG D, et al. Understanding and learning discriminant features based on multi-attention IDCNN for wheelset bearing fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2020, 16(9): 5735-5745.
- [13] 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 Niaoqing, CHEN Huipeng, CHENG Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks [J]. Journal of Mechanical Engineering, 2019, 55(7): 9-18.(in Chinese)
- [14] XUE W, AI H, SUN T Y, et al. Frame-GAN: increasing the frame rate of gait videos with generative adversarial networks [J]. Neurocomputing, 2020, 380: 95-104.
- [15] ZHANG M R, LUCAS J, HINTON G, et al. Lookahead optimizer: k steps forward, 1 step back [EB/OL]. [2019-07-01]. <http://arXiv preprint arXiv:1907.08610>
- [16] PASSALIS N, TEFAS A. Dimensionality reduction using similarity-induced embeddings [J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(8): 3429-3441.
- [17] 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): 124-131.
LI Heng, ZHANG Qing, QIN Xianrong, et al. Fault diagnosis method for rolling bearings based on short-time Fourier transform and convolution neural network [J]. Journal of Vibration and Shock, 2018, 37(19): 124-131.(in Chinese)



第一作者简介:熊焯,男,1983年11月生,博士、讲师、硕士生导师。主要研究方向为设备故障预诊与健康评估。曾发表《A new procedure for extracting fault feature of multi-frequency signal from rotating machinery》(《Mechanical Systems and Signal Processing》2012, Vol.32)等论文。

E-mail: xxiong@shu.edu.cn