

箱型图与特征融合模型在轮对轴承标签混淆 数据分类中的应用

张 雄^{1,2}, 李嘉禄², 董 帆², 武文博², 万书亭^{1,2}, 顾晓辉³

(1. 河北省电力机械装备健康维护与失效预防重点实验室, 河北 保定 071003;

2. 华北电力大学机械工程系, 河北 保定 071003;

3. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室, 河北 石家庄 050043)

摘要: 深度学习方法和列车轮对轴承故障诊断领域表现出了巨大的潜力,但其可以有效实现的前提是各类数据与类别标签之间能够正确匹配,对于含有少量标签错误样本的数据,传统深度学习方法难以实现预期的诊断效果。针对此问题,提出了一种箱型图法与特征融合模型相结合的故障诊断方法。利用列车轮对轴承实验数据对所提方法进行验证,结果表明,相比于直接利用传统神经网络模型进行故障诊断,本文所提方法的诊断准确率更高,说明本文方法对于含有少量标签错误样本的轴承数据具有更好的处理效果。

关键词: 故障诊断; 轮对轴承; 标签错误; 特征融合; 箱型图

中图分类号: TH165+.3; TH133.3 **文献标志码:** A **文章编号:** 1004-4523(2025)01-0088-08

DOI: 10.16385/j.cnki.issn.1004-4523.2025.01.010

The application of box graph and feature fusion model in the classification of wheel set bearing label confusion data

ZHANG Xiong^{1,2}, LI Jialu², DONG Fan², WU Wenbo², WAN Shuting^{1,2}, GU Xiaohui³

(1. Hebei Key Laboratory of Electric Machinery Health Maintenance & Failure Prevention, Baoding 071003, China; 2. Department of Mechanical Engineering, North China Electric Power University, Baoding 071003, China; 3. State Key Laboratory of Mechanics Behavior and System Safety of Traffic Engineering Structures, Shijiazhuang Tiedao University, Shijiazhuang 050043, China)

Abstract: Deep learning methods have shown great potential in the field of fault diagnosis of train wheelset bearings, but their effective implementation is based on the correct matching between various types of data and category labels. For data with a small number of label error samples, traditional deep learning methods are difficult to achieve the expected diagnostic effect. To address this issue, this paper proposes a fault diagnosis method combining box graph method and feature fusion model is proposed to address this issue. In this method, the outlier in each group of bearing signals is removed by box graph method, and the remaining data is expanded by the SMOTE method to restore to the original data size; Input the processed sample data into the improved feature fusion model for fault identification and classification. The experimental data of train wheel bearings was used for validation. The results showed that compared to directly using traditional neural network models for fault diagnosis, the diagnostic accuracy of the method proposed in this paper is higher, indicating that the method has better processing performance for bearing data with a small number of label error samples.

Keywords: fault diagnosis; wheel set bearings; label error; feature fusion; box graph

轮对轴承作为列车运行的核心部件,其健康状况会对列车的运行性能和安全状况产生重要影响^[1-3]。因此,对列车轮对轴承进行及时有效的故障识别与诊断具有极其重要的意义^[4-5]。

深度学习具有极强的自适应特征提取能力^[6],

在轴承数据的分析过程中有效地减少了人工干预和经验误差,被越来越多的人用于列车轴承的故障诊断。杨劫立等^[7]先用最小熵解卷积方法对振动信号进行处理,然后将处理后的信号与原始振动信号组合构建二维张量图,以此作为卷积神经网络模型的

输入,进行列车轴承的故障识别与诊断。邓飞跃等^[8]提出了一种轻量级神经网络,通过分组卷积与深度可分离卷积提高了网络的运行效率,通过通道混洗的方法提高了网络的损失精度,相比于传统神经网络诊断效率有了极大提升。姚德臣等^[9]将轴承振动信号转换为灰度图,再用卷积神经网络对得到的灰度图样本进行分析,可以有效识别城轨列车轴承故障。沈长青等^[10]使用 ResNet-50 网络提取数据的中间层次特征,在此基础上通过构建的多尺度特征提取器提取高层次的特征,最后输入至分类器进行故障诊断,用于处理变工况下列车轴承的故障诊断问题。罗宏林等^[11]将不同工况下提取的信号特征向量集通过监督式自编码器向标准工况下的信号特征做迁移,再将迁移后的信号特征输入由参考工况训练集特征预训练的卷积神经网络进行故障识别,实现了变工况下列车轴承的故障诊断。张青松等^[12]将原始信号进行变分模态分解,然后计算各模态分量的参数优化 Hurst 指数特征值,最后将特征向量输入支持向量机中进行分析,用于高速列车轮对轴承微弱故障特征信息的识别。

以上研究皆是针对各类标签与信号类型对应完全正确的情况进行的分析,但在某些情况下,由于人为操作的失误,在对采集到的信号设置标签时会产生误差,导致一类信号的多个样本中含有部分标签错误的样本,这对于信号的特征提取会产生极大的干扰,使用传统的深度学习模型对此类数据进行识别诊断也难以达到预期的效果。列车轮对轴承数据采集相对困难,由于少量标签错误样本而再次采集新数据会浪费大量的时间和资源,因此,有必要解决信号采集过程中可能出现的标签混淆问题,削弱标签混淆对诊断模型的影响,使得该类数据具有可用性。针对此问题,本文提出了一种箱型图法与特征融合相结合的诊断方法(box graph method and feature fusion, BFF),该方法先利用箱型图法去除数据中的异常值,获得分布均匀的数据;然后用 SMOTE 方法对新数据进行扩充,恢复到原始数据量大小;最后将处理过后的数据输入到改进的特征融合模型中进行故障识别与诊断。利用列车轮对轴承实验数据验证了本文所提方法对于含有少量标签错误样本的数据有较好的分类效果,并与一些传统的诊断方法进行对比。

1 基本理论

1.1 箱型图法

箱型图是一种用于显示一组数据分散情况的统

计图,其主要原理是利用数据中的下限、第一四分位数、中位数、第三四分位数和上限五个统计量来对数据进行描述。其主要参数定义如表 1 所示,示意图如图 1 所示。箱型图可以不受异常值的影响,稳定地描绘出数据的离散分布情况,同时也有利于进行数据清洗和不同样本数据之间的比较。将箱型图中位于图形上下限之外的离群点归为数据中的异常值,本文对于原始数据的清洗方法就是清除箱型图法中的数据异常值。当不同标签的样本混淆时,由于不同故障类型的振动峰值不同,表现在数据层面就是一组混淆数据中的离群点分布散乱,在利用深度学习对数据进行特征提取时,散乱分布的离群点会导致学习到的特征出现偏差,从而影响对于数据类型的判断。本文利用箱型图法去除标签混淆数据中的离群点之后,大量原始数据得以保留,此时虽然仍有标签错误样本数据混杂在内,但其和标签正确样本数据都已被归一化到了一个标准范围之内,再无特殊的离群点可以对特征提取过程进行干扰。由于在深度学习过程中会对数据量较大的部分进行重点学习,其总结的特征“规律”也会以正确数据的特征为主,这样就可以极大程度上降低少量标签错误样本对学习过程的干扰,使一组标签混淆数据具有可用性。

表 1 箱型图参数定义

Tab. 1 Box graph parameter definition

参数	参数定义
第一四分位数 Q1	一组样本中所有数值由小到大排列后第 25% 的数字
中位数 Q2	一组样本中所有数值由小到大排列后第 50% 的数字
第三四分位数 Q3	一组样本中所有数值由小到大排列后第 75% 的数字
四分位距离 IQR	$Q3 - Q1$
上限	$Q3 + 1.5 \times IQR$
下限	$Q1 - 1.5 \times IQR$

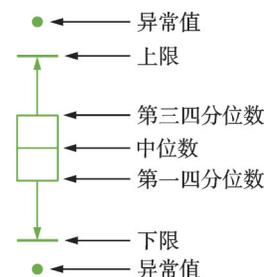


图 1 箱型图原理示意图

Fig. 1 Schematic diagram of box graph principle

1.2 SMOTE 算法

SMOTE 算法的主要思想是采用线性插值的方

式在少数类样本和 k 近邻样本之间合成新的少数类样本^[13-14],它在一定程度上解决了随机过采样造成的信息冗余问题^[15]。本文采用的列车轴承数据为平衡数据,不存在少数类样本,为了适应 SMOTE 算法的原理,将整体数据作为少数类样本进行插值处理,实现对原始数据的扩充。

算法具体流程如下:

(1)对每一个样本 x ,以欧氏距离为标准,计算它到样本集中所有其他样本的距离,得到其 k 近邻。

(2)设置新数据的生成倍率 N ,对每一个样本 x ,从其 k 近邻中随机选择若干个样本,假设选择的近邻为 x_n 。

(3)对每一个随机选出的近邻 x_n ,分别与原样本按照下式构建新的样本:

$$x_{new} = x + rand(0, 1) \cdot |x - x_n| \quad (1)$$

式中, x_{new} 代表最终合成的一个样本; x 表示输入的样本; x_n 表示选择 x 的一个近邻样本; $rand(0, 1)$ 表示 0 和 1 之间的一个随机数。

1.3 全卷积神经网络

卷积神经网络具有强大的特征自提取能力,同时可以通过局部权值共享的方式有效降低模型的复杂度和减小计算量。传统的 CNN 结构由输入层、卷积层、池化层、全连接层以及输出层组成^[16-18]。输入层的作用是接收传入神经网络的信号,卷积层的作用是对输入的信号进行卷积运算从而提取重要特征^[19],其卷积原理如图 2 所示。池化层一般用于对卷积层提取的特征进行降维^[20],以减少运算量。本文实验模型去除了池化层,构建全卷积神经网络,最大程度地保留卷积层提取的特征信息。全连接层将前面一系列处理后输出的二维特征矩阵转化成一个一维向量,把特征整合到一起,大大减少特征位置对分类带来的影响。但全连接层的参数过多,会加大网络的训练难度。本文使用全局平均池化层取代全连接层,不仅可以实现全连接层的功能,还可以减少参数数量,避免过拟合^[21]。输出层位于整个神经网络结构的最后,将从前面得到的特征进行分类输出。

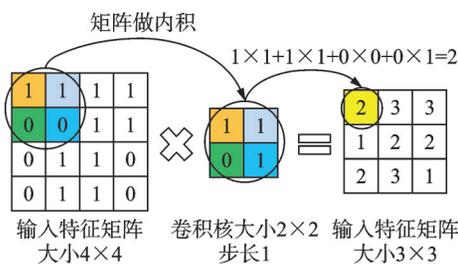


图 2 卷积原理示意图

Fig. 2 Schematic diagram of convolution principle

1.4 长短时记忆神经网络

LSTM 是循环神经网络的改进模型,相对于传统的 RNN 网络,LSTM 的记忆力更强,更有利于处理长时序信号数据^[22]。其核心思想是通过遗忘不同程度的长时记忆,并加上此刻产生的短时记忆,来控制此刻经过长短时记忆网络所产生的输出值^[23]。LSTM 单元的基本结构如图 3 所示,主要包括遗忘门、输入门、输出门和记忆细胞^[24]。遗忘门用来记录长时记忆的遗忘程度,决定上一时刻的记忆细胞状态有多少保留到此刻的记忆细胞状态;输入门用来记录当前时刻的短时记忆,决定这一时刻有多少信息被保留;输出门用来作为长短时记忆网络最后的输出。

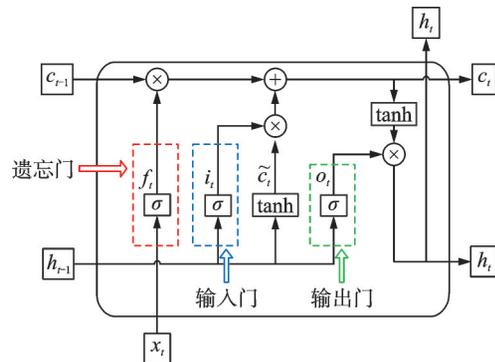


图 3 LSTM 单元结构图

Fig. 3 LSTM unit structure diagram

2 特征融合模型

传统的并行神经网络模型只在决策层进行特征融合,难以及时获取两条支路各自提取的特征信息,也不利于训练过程的可视化展示。本文模型对此进行了改进,以全卷积神经网络和长短期记忆神经网络为并行支路,在每个卷积层和 LSTM 层之后都进行一次特征矩阵的相加融合,将新融合的数据作为下一次特征提取的输入。本文模型不仅可以及时获取各条支路的特征信息,还可以在融合节点处进行可视化展示,有效避免了深度学习中的黑盒子问题。本文模型去除了传统卷积神经网络中的池化层,充分利用卷积神经网络强大的特征提取能力,最大程度地保留数据的特征信息。同时利用长短期记忆神经网络提取轴承信号的时间特征,将两者进行结合,使提取到的特征更加充分。此外,本文在模型中加入了 BN 层和 Dropout 层,可以起到加快训练和收敛的速度以及防止过拟合的作用。在模型最后用全局平均池化层取代全连接层,减少模型的参数量,达到简化模型、提高运算效率的效果。具体模型参数如表 2 和 3 所示。

表 2 卷积神经网络参数设置

Tab. 2 Parameter settings for convolutional neural networks

全卷积神经网络结构	参数设置
卷积层 C1	卷积核数 16,卷积核尺寸 25
批量归一化层 B1	—
卷积层 C2	卷积核数 32,卷积核尺寸 3
批量归一化层 B2	—
卷积层 C3	卷积核数 64,卷积核尺寸 3
批量归一化层 B3	—

表 3 LSTM 神经网络参数设置

Tab. 3 Parameter setting of LSTM neural network

LSTM 神经网络结构	参数设置
LSTM-1	神经元数 16
Dropout-1	0.2
LSTM-2	神经元数 32
Dropout-2	0.2
LSTM-3	神经元数 64
Dropout-3	0.2

3 故障诊断流程

故障诊断流程如图 4 所示,主要分为三部分。第一部分为原始信号的选取,本文采用列车轮对轴承实验数据构建标签混淆数据集,将包含少量标签错误样本的 3 类数据作为模型的输入。第二部分为数据的预处理,包括箱型图法去除异常值和 SMOTE 法扩充数据集;将扩充后的数据进行打乱与重组,并按照 8:2 的比例划分为训练集和测试集。

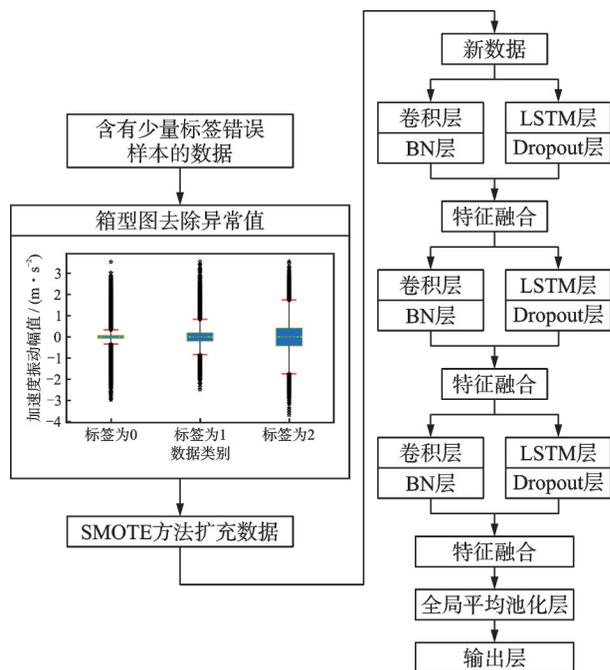


图 4 故障诊断流程

Fig. 4 Fault diagnosis process

第三部分为模型参数调整与轴承故障的识别与诊断。

4 列车轮对轴承实验数据分析

4.1 数据预处理

本实验采用的数据来自列车轮对轴承实验,该实验平台由列车轮组、加速度传感器和轮轴轴承等组成,如图 5 所示。轴承内圈和外圈故障情况如图 6 和 7 所示。



图 5 列车轮对轴承实验台

Fig. 5 Train wheelset bearing experimental platform



图 6 内圈故障

Fig. 6 Inner race fault



图 7 外圈故障

Fig. 7 Outer race fault

本实验选取其中的内圈故障、外圈故障和健康状态等情况下的数据进行标签混淆数据集的构建。将每类数据分成 250 组,每组 1024 个采样点,其标签设置如表 4 所示。将标签为 0 时定义为正常数据,其中包含 225 组正常数据和 25 组外圈故障数据;将标签为 1 时定义为内圈故障数据,其中包含 225 组内圈

表 4 数据类型及标签编号

Tab. 4 Data type and tag number

数据类型	标签编号
225 组正常样本 + 25 组外圈故障样本	0
225 组内圈故障样本 + 25 组正常样本	1
225 组外圈故障样本 + 25 组内圈故障样本	2

故障数据和 25 组正常数据;将标签为 2 时定义为外圈故障数据,其中包含 225 组外圈数据和 25 组内圈故障数据。

绘制三类数据的箱型图,如图 8 所示。其中蓝色部分为箱型图的箱体。箱体中的虚线为数据的中位数,箱体的上下边缘分别为数据的第三四分位点和第一四分位点,箱体上下的两条红色短线分别为箱型图法定义的数据上下限。由图可知,上下限之外的所有点皆为数据中的异常值,对异常值进行删除,得到三组分布均匀的数据。将原始数据时域图与去除异常值之后数据的时域图进行对比,如图 9 所示(其中 0, 1, 2 分别为各组数据对应的标签编号)。由图可知,进行箱型图去除异常值处理后,各组数据的极端点都已经被删除,新数据分布较为均匀,且整体波形与原始数据一致,没有发生变化。

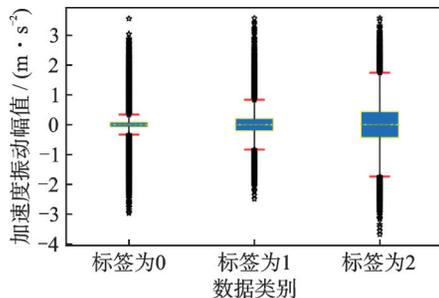


图 8 箱型图

Fig. 8 Box graph

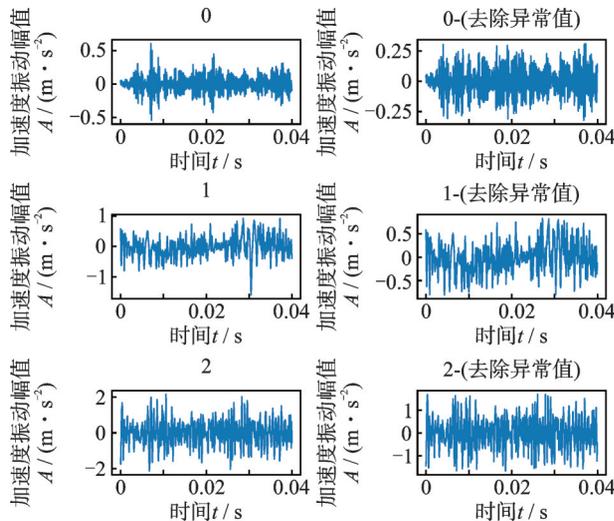


图 9 去除异常值后新数据与原始数据对比

Fig. 9 Comparison between new data and original data after removing outlier

由于经箱型图处理后有部分数据被去除,导致数据量减少;并且各组数据的去除量不同,会导致轻微的数据不平衡现象。为了避免这种情况,对新数据进行 SMOTE 数据扩充处理,将合成的新数据与原数据进行对比,如图 10 所示。可知,在对应的同一组样本内,合成信号的波形与原始信号的波形极

其相似,说明合成信号极其接近于原始信号。按照三类情况下数据各自的缺失情况,选取相应的合成样本数据,将信号补齐至原始数据量大小。这样每类情况仍旧有 250 组数据,每组数据包含 1024 个数据点。分别将 250 组数据分为训练组和测试组。

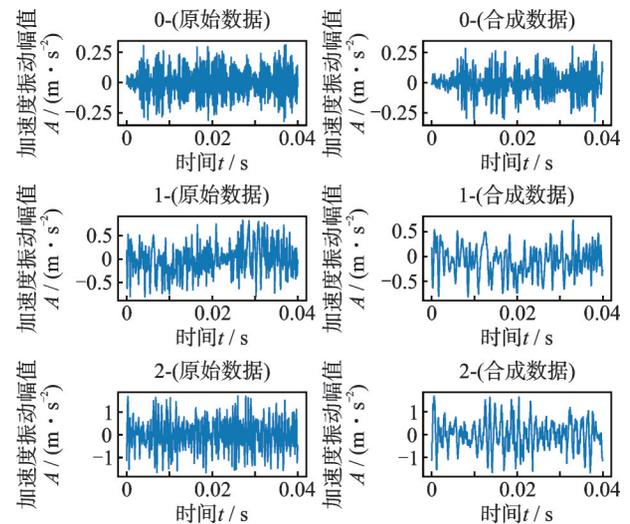


图 10 原始数据与合成数据对比

Fig. 10 Comparison between original data and synthesized data

4.2 实验与结果分析

本文实验中采用的深度学习框架为 Tensorflow,计算机配置为:Core(TM) i5-8265U CPU 处理器和 NVIDIA GeForce MX230 显卡。

将数据输入改进的特征融合模型中进行训练,迭代 200 次后训练停止。本实验模型使用 Adam 优化器自动优化学习率,使用交叉熵损失函数作为目标函数来指导网络参数的学习。训练和测试的准确率曲线如图 11 所示,损失曲线如图 12 所示。

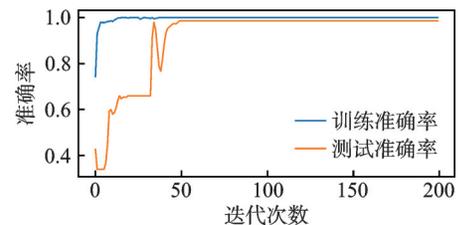


图 11 训练和测试准确率曲线

Fig. 11 Training and testing accuracy curve

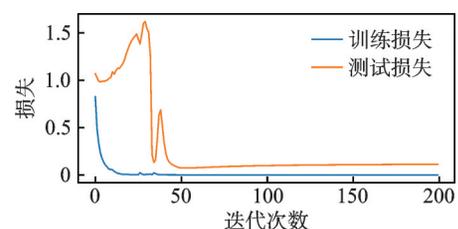


图 12 训练和测试损失曲线

Fig. 12 Training and testing loss curve

由图 11 和 12 可知,训练集的准确率曲线在迭代 40 次左右的时候已经完全收敛,准确率达到 100%;损失曲线随着迭代迅速下降,在 40 次左右完全收敛,损失无限接近于 0。测试集的准确率在迭代 50 次左右的时候已经达到了 98.67%;损失随着迭代迅速下降,在 100 次左右完全收敛,达到一个极小值。图 13 为测试集的混淆矩阵,其横坐标为预测标签,纵坐标为实际标签。由混淆矩阵可知,测试过程中在标签为 0 的类别上识别准确率达到 100%,在标签为 1 和 2 的类别上有些许误差,但也达到了极高的识别准确率。图 14 为训练时整体过程的可视化图像,由图可知,初始数据分布较为混乱,难以有效区分。随着训练的进行,相同类型的数据点逐渐聚集,不同类型的数据点逐渐分散,最终各类数据完全分开。说明训练起到了极好的分类效果,同时也证明了本文方法对于包含少量标签错误样本的轮对轴承数据具有很好的诊断效果。

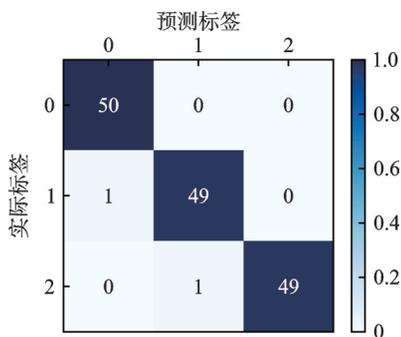


图 13 测试集混淆矩阵

Fig. 13 Test set confusion matrix

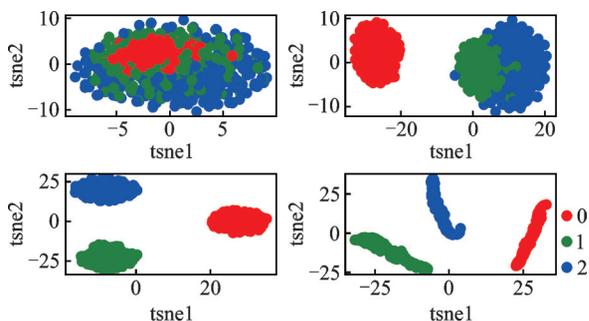


图 14 整体过程可视化

Fig. 14 Overall process visualization

4.3 不同故障诊断方法对比

为验证本文所提方法的优越性,与 3 种典型诊断方法进行对比。训练过程中统一设置 batchsize 为 128,迭代次数为 500。将最后的测试曲线进行可视化展示,如图 15 和 16 所示。由结果可知,本文所提方法的效果最好,准确率曲线和损失曲线在各种方法中均收敛得最快,准确率达到各种方法中最高 98.67%,损失在各种方法中最低,无限接近于 0。相比之下,直接用 ShuffleNetV1、GhostNet 和 Mo-

bileNetV2 进行诊断的效果则较差,三种方法的测试准确率只能维持在 87% 左右,测试损失也远高于本文所提 BFF 方法。并且在 batchsize 和迭代次数相同的情况下,三种典型方法的测试曲线波动较大,难以有效的收敛,诊断效果欠佳。

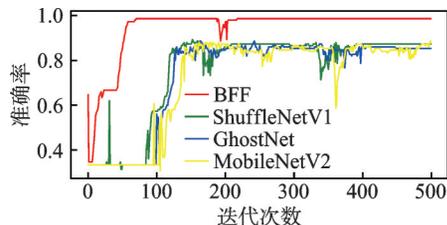


图 15 不同诊断方法准确率曲线

Fig. 15 Accuracy curves of different diagnostic methods

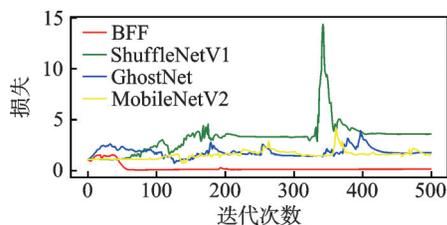


图 16 不同诊断方法损失曲线

Fig. 16 Loss curves of different diagnostic methods

4.4 方法泛化性验证

为检验本文方法的泛化性,对标签错误样本个数进行调整,设置标签正确样本与标签错误样本比例为 8:2 和 7:3 两种情况进行分析,如表 5 所示。

表 5 样本比例设置

Tab. 5 Sample scale setting

标签设置情况	标签定义为正常	标签定义为内圈故障	标签定义为外圈故障
8:2	200 组正常样本 + 50 组外圈故障样本	200 组内圈故障样本 + 50 组正常样本	200 组外圈故障样本 + 50 组内圈故障样本
7:3	175 组正常样本 + 75 组外圈故障样本	175 组内圈故障样本 + 75 组正常样本	175 组外圈故障样本 + 75 组内圈故障样本

用本文所提 BFF 方法对两种情况下的数据进行分析,结果如图 17 所示。可知,随着同组中标签错误样本比例的增加,使用 BFF 方法诊断所得的测试准确率会有一定的下降,但即使标签错误样本占比达到 30% 时,使用本文方法进行诊断的测试准确率仍旧可以达到 92%。与 ShuffleNetV1、GhostNet 和 MobileNetV2 方法相比,本文所提方法在两种情况下得到的测试准确率都具有极大优势,说明其在数据集中标签错误样本数量占比较高的情况下也有很好的诊断效果。

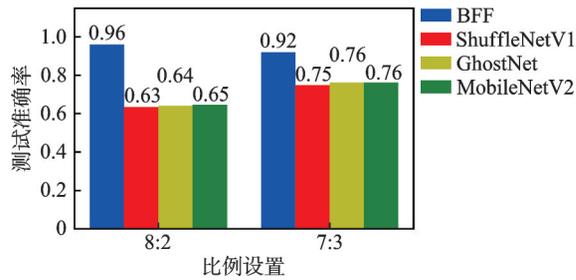


图17 不同标签错误样本占比下各诊断方法的测试准确率
Fig.17 Test accuracy of various diagnostic methods under different proportion of label error samples

5 结论

为解决训练样本中含有少量标签错误样本导致列车轴承诊断难度增大的问题,本文提出了一种BFF方法。该方法主要有以下优点:

(1) 使用箱型图法去除数据中的异常值,对数据进行清洗,获得分布较为均匀的数据,更有利于数据特征的提取。

(2) 使用SMOTE方法对清洗后的数据进行扩充,避免因数据量减少而导致诊断结果不准确的情况以及各组训练数据数量不平衡问题的发生。

(3) 使用改进的特征融合模型进行故障识别与诊断,既能及时获取融合后的信息,又可以进行全过程可视化展示,有效避免了深度学习的黑盒子问题。

(4) 分别用BN层和Dropout层对神经网络模型进行优化,加快了训练和收敛的速度,增强了模型的稳定性。

(5) 用全局平均池化层代替全连接层,有效减少了模型的参数数量,提升了运算速度。使用BFF方法对含有少量标签错误样本的列车轮对轴承数据进行故障识别与诊断,取得了极佳的效果,证明了本文所提方法的有效性和优越性。

参考文献:

- [1] 王宝森,刘永强,张斌.变转速工况下高速列车轴承转子系统特性分析[J].力学学报,2022,54(7):1839-1852.
WANG Baosen, LIU Yongqiang, ZHANG Bin. Characteristics analysis on bearing rotor system of high-speed train under variable speed conditions[J]. Chinese Journal of Theoretical and Applied Mechanics, 2022, 54(7):1839-1852.
- [2] 李翠省,廖英英,刘永强.基于EEMD和参数自适应VMD的高速列车轮对轴承故障诊断[J].振动与冲击,2022,41(1):68-77.
LI Cuixing, LIAO Yingying, LIU Yongqiang. Fault diagnosis of wheelset bearing of high-speed train based on

EEMD and parameter adaptive VMD[J]. Journal of Vibration and Shock, 2022, 41(1):68-77.

- [3] 刘方,翟涛涛,侯超强,等.基于多普勒调制时移Laplace小波的列车轴承故障声信号瞬态成分快速提取方法[J].仪器仪表学报,2022,43(3):40-48.
LIU Fang, ZHAI Taotao, HOU Chaoqiang, et al. A fast transient component extraction method of train bearing fault acoustic signal based on Doppler modulated time-shifting Laplace wavelet [J]. Chinese Journal of Scientific Instrument, 2022, 43(3):40-48.
- [4] 黄晨光,林建辉,易彩,等.延伸奇异值分解包及其在高速列车轮对轴承故障诊断中的应用[J].振动与冲击,2020,39(5):45-56.
HUANG Chengguang, LIN Jianhui, YI Cai, et al. Extended SVD packet and its application in wheelset bearing fault diagnosis of high-speed train[J]. Journal of Vibration and Shock, 2020, 39(5):45-56.
- [5] 顾晓辉,杨绍普,刘文朋,等.高速列车轴箱轴承健康监测与故障诊断研究综述[J].力学学报,2022,54(7):1780-1796.
GU Xiaohui, YANG Shaopu, LIU Wenpeng, et al. Review of health monitoring and fault diagnosis of axle-box bearing of high-speed train[J]. Chinese Journal of Theoretical and Applied Mechanics, 2022, 54(7):1780-1796.
- [6] 刘玉鑫,武文博,张雄,等.基于HHO-CNN的轴承故障诊断方法研究[J].河北大学学报(自然科学版),2023,43(6):571-583.
LIU Yuxin, WU Wenbo, ZHANG Xiong, et al. Fault detection method of bearings based on HHO-CNN[J]. Journal of Hebei University (Natural Science Edition), 2023, 43(6):571-583.
- [7] 杨劼立,林建辉,谌亮.基于MED辅助特征提取CNN模型的列车轴承故障诊断方法[J].中国测试,2020,46(10):124-129.
YANG Jieli, LIN Jianhui, CHEN Liang. Fault diagnosis method for train bearings based on MED-assisted feature extraction CNN model[J]. China Measurement & Test, 2020, 46(10):124-129.
- [8] 邓飞跃,丁浩,吕浩洋,等.一种基于轻量级神经网络的高铁轮对轴承故障诊断方法[J].工程科学学报,2021,43(11):1482-1490.
DENG Feiyue, DING Hao, LYU Haoyang, et al. Fault diagnosis of high-speed train wheelset bearing based on a lightweight neural network[J]. Chinese Journal of Engineering, 2021, 43(11):1482-1490.
- [9] 姚德臣,刘恒畅,杨建伟,等.基于深度学习的城轨列车轴承复合故障诊断研究[J].铁道学报,2021,43(6):37-44.
YAO Dechen, LIU Hengchang, YANG Jianwei, et al. Diagnosis of compound faults of bearings of urban rail train based on deep learning model[J]. Journal of the China Railway Society, 2021, 43(6):37-44.
- [10] 沈长青,王旭,王冬,等.基于多尺度卷积类内迁移学习的列车轴承故障诊断[J].交通运输工程学报,2020,20

- (5):151-164.
SHEN Changqing, WANG Xu, WANG Dong, et al. Multi-scale convolution intra-class transfer learning for training bearing fault diagnosis[J]. Journal of Traffic and Transportation Engineering, 2020,20(5):151-164.
- [11] 罗宏林,柏林,侯东明,等.有限变工况特征迁移学习方法及其在高速列车轴箱轴承故障诊断中的应用[J].仪器仪表学报,2022,43(3):132-145.
LUO Honglin, BO Lin, HOU Dongming, et al. A transfer learn method for bearing fault diagnosis under finite variable working conditions and its application in training axle-box bearing fault diagnosis[J]. Chinese Journal of Scientific Instrument, 2022,43(3):132-145.
- [12] 张青松,张兵,秦怡.基于改进VMD和APSO-SVM的高速列车轴承故障诊断[J].机车电传动,2022,284(1):31-36.
ZHANG Qingsong, ZHANG Bing, QIN Yi. Bearing fault diagnosis for high-speed train based on improved vmd and APSO-SVM[J]. Electric Drive for Locomotives, 2022, 284(1): 31-36.
- [13] 刘云鹏,和家慧,许自强,等.基于SVM SMOTE的电力变压器故障样本均衡化方法[J].高电压技术,2020,46(7):2522-2529.
LIU Yunpeng, HE Jiahui, XU Ziqiang, et al. Equalization method of power transformer fault sample based on SVM SMOTE[J]. High Voltage Engineering, 2020,46(7):2522-2529.
- [14] 陶新民,刘福荣,童智靖,等.不平衡数据下基于SVM的故障检测新算法[J].振动与冲击,2010,29(12):8-12.
TAO Xinmin, LIU Furong, TONG Zhijing, et al. Novel fault detection method based on SVM with unbalanced datasets[J]. Journal of Vibration and Shock, 2010, 29(12):8-12.
- [15] 李艳霞,柴毅,胡友强,等.不平衡数据分类方法综述[J].控制与决策,2019,34(4):673-688.
LI Yanxia, CHAI Yi, HU Youqiang, et al. Review of imbalanced data classification methods[J]. Control and Decision, 2019,34(4):673-688.
- [16] 董绍江,李洋,梁天,等.基于CNN-BiLSTM的滚动轴承变工况故障诊断方法[J].振动、测试与诊断,2022,42(5):1009-1016.
DONG Shaojiang, LI Yang, LIANG Tian, et al. Fault diagnosis method of rolling bearing based on CNN-BiLSTM under variable working conditions[J]. Journal of Vibration, Measurement & Diagnosis, 2022,42(5):1009-1016.
- [17] 余志锋,熊邦书,熊天旸,等.基于VMD-CWT和改进CNN的直升机轴承故障诊断[J].航空动力学报,2021,36(5):948-958.
YU Zhifeng, XIONG Bangshu, XIONG Tianyang, et al. Fault diagnosis of helicopter bearing based on VMD-CWT and improved CNN[J]. Journal of Aerospace Power, 2021,36(5):948-958.
- [18] 宫文峰,陈辉,张泽辉,等.基于改进卷积神经网络的滚动轴承智能故障诊断研究[J].振动工程学报,2020,33(2):400-413.
GONG Wenfeng, CHEN Hui, ZHANG Zehui, et al. Intelligent fault diagnosis for rolling bearing based on improved convolutional neural network[J]. Journal of Vibration Engineering, 2020,33(2):400-413.
- [19] 王奉涛,薛宇航,王洪涛,等.GLT-CNN方法及其在航空发动机中介轴承故障诊断中的应用[J].振动工程学报,2019,32(6):1077-1083.
WANG Fengtao, XUE Yuhang, WANG Hongtao, et al. GLT-CNN and its application of aero-engine intermediary bearing fault diagnosis[J]. Journal of Vibration Engineering, 2019,32(6):1077-1083.
- [20] 康涛,段蓉凯,杨磊,等.融合多注意力机制的卷积神经网络轴承故障诊断方法[J].西安交通大学学报,2022,56(12):68-77.
KANG Tao, DUAN Rongkai, YANG Lei, et al. Bearing fault diagnosis using convolutional neural network based on a multi-attention mechanism[J]. Journal of Xi'an Jiaotong University, 2022,56(12):68-77.
- [21] 张俊红,孙诗跃,朱小龙,等.基于改进卷积神经网络的柴油机故障诊断方法研究[J].振动与冲击,2022,41(6):139-146.
ZHANG Junhong, SUN Shiyue, ZHU Xiaolong, et al. Diesel engine fault diagnosis based on an improved convolutional neural network[J]. Journal of Vibration and Shock, 2022,41(6):139-146.
- [22] 王磊,孙志成,王磊,等.基于DRSN-CW和LSTM的轴承故障诊断[J].电子科技大学学报,2022,51(6):921-927.
WANG Lei, SUN Zhicheng, WANG Lei, et al. Bearing fault diagnosis based on DRSN-CW and LSTM[J]. Journal of University of Electronic Science and Technology of China, 2022,51(6):921-927.
- [23] 欧阳励,何水龙,朱良玉,等.一种基于双向长短期记忆结构与多尺度卷积结构融合的轴承智能故障诊断方法[J].振动与冲击,2022,41(19):179-187.
OUYANG Li, HE Shuilong, ZHU Liangyu, et al. An intelligent bearing fault diagnosis method based on fusion of bidirectional LSTM structure and MSC structure [J]. Journal of Vibration and Shock, 2022, 41(19): 179-187.
- [24] 池永为,杨世锡,焦卫东.基于LSTM-RNN的滚动轴承故障多标签分类方法[J].振动、测试与诊断,2020,40(3):563-571.
CHI Yongwei, YANG Shixi, JIAO Weidong. A multi-label fault classification method for rolling bearing based on LSTM-RNN [J]. Journal of Vibration, Measurement & Diagnosis, 2020,40(3):563-571.

第一作者:张 雄(1990—),男,博士,副教授。

E-mail:hdjxx@ncepu.edu.cn

通信作者:万书亭(1970—),男,博士,教授。

E-mail:13582996591@139.com