

DOI: 10.19650/j.cnki.cjsi.J1905527

代价敏感卷积神经网络:一种机械故障数据不平衡分类方法^{*}

董勋^{1,2}, 郭亮^{1,2}, 高宏力^{1,2}, 刘宸宇^{1,2}, 李磊^{1,2}

(1. 西南交通大学先进驱动节能技术教育部工程研究中心 成都 610031; 2. 西南交通大学机械工程学院 成都 610031)

摘要:机械设备实际工作过程中正常样本丰富、故障样本匮乏,卷积神经网络在处理这种分布不平衡的数据时对少数类的识别率很低。为解决上述问题,提出一种代价敏感卷积神经网络,首先经过多层卷积和池化运算学习原始监测数据中的机械设备本征性能状态知识;其次通过全连接层将本征性能状态知识映射为机械设备健康状态;最后利用代价敏感损失函数为少数类样本赋予较大的误分类代价,实现对不平衡的机械故障数据的有效分类。为验证所提方法的有效性,使用具有不同不平衡比的刀具数据集和轴承数据集,利用代价敏感卷积神经网络以及主流的分类算法分别测试其对于不平衡数据的分类性能。实验结果表明,所提方法对不平衡数据集中的少数类样本识别率相对于传统卷积神经网络提升了22%以上。

关键词: 代价敏感;卷积神经网络;不平衡分类;智能故障诊断

中图分类号: TH878 TG115.28 **文献标识码:** A **国家标准学科分类代码:** 460.40

Cost sensitive convolutional neural network: a classification method for imbalanced data of mechanical fault

Dong Xun^{1,2}, Guo Liang^{1,2}, Gao Hongli^{1,2}, Liu Chenyu^{1,2}, Li Lei^{1,2}

(1. *Engineering Research Center of Advanced Driving Energy-saving Technology, Ministry of Education, Southwest Jiaotong University, Chengdu 610031, China*; 2. *School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China*)

Abstract: In the actual operation of machinery, the normal data are abundant and the fault data are rare. The recognition rate of the minority class is low when the convolutional neural network is used to process these imbalanced data. To solve this problem, an imbalanced fault diagnosis method for machinery based on the cost sensitive convolutional neural network is proposed. Firstly, the intrinsic performance state knowledge is achieved in raw data of machinery through multi-level convolution and pooling operations. Then, the intrinsic performance state knowledge is mapped to mechanical health by fully connected layer. Finally, the cost sensitive loss function is used to set a large cost to the misclassification of the minority class. The effective classification of mechanical imbalanced data is realized. The proposed method is evaluated by tool monitoring data and bearing monitoring data with different imbalanced ratio. Compared with the traditional convolutional neural networks, experimental results show that the recognition rate of minority samples in imbalanced datasets has been improved by more than 22%.

Keywords: cost sensitive; convolutional neural network; imbalanced classification; intelligent fault diagnosis

0 引言

机械设备的结构复杂性与功能耦合性决定任何微小故障都可能引发连锁反应,因而对其实施全面实时监测势在必行^[1-3]。机械设备智能故障诊断方法从监测信号中提取隐含的故障特征知识^[4],通过智能算法自动识别设备健康状态,是当前故障诊断领域的研究热点^[5-7]。自2006年Hinton等^[8]首次提出“深度学习”概念至今,深度学习技术在学术界和产业界都已成为新兴的研究热点,深度神经网络在不同的工程领域也已得到了成功应用,如图像识别^[9-10]、文本分析^[11]、语音识别^[12]、故障诊断^[13-18]、寿命预测^[19-21]等。Jing等^[14]提出基于卷积神经网络的特征学习和故障诊断方法,对齿轮箱故障识别率达98%。张伟^[15]提出的第一层宽卷积核深度卷积神经网络(deep convolutional neural networks with wide first-layer kernel, WDCNN)在轴承故障诊断中达到了很好的效果。Jia等^[16]提出了基于深度神经网络的轴承故障诊断方法,该方法与浅层网络相比取得了更高的故障识别率。Guo等^[17]提出的深度卷积迁移学习网络(deep convolutional transfer learning network, DCTLN)实现了对轴承未标记数据的有效分类。

上述应用在机械智能故障诊断领域的深度学习方法在平衡数据集中均取得了良好的故障识别效果,但是以上研究内容未考虑不同机械健康状态样本的不平衡分布。一般而言,机械设备几乎都处在正常状态,导致传感器采集的数据服从长尾分布,即设备处在正常状态下的样本丰富,故障状态下的样本稀少。在处理这种分布不平衡的数据时,上述智能故障诊断方法往往以提高总体样本分类精度为目标,将所有样本一视同仁,数据量的不平衡迫使这些方法偏向于多数类样本^[15],因而对少数类样本的特征了解不足,导致大部分少数类样本易被忽略。然而,在工业监测中,机械设备故障作为少数类发生,却需要比多数类(设备正常运行)引起更多关注,如果这种少数类被误判为多数类,将会错过最佳的设备维护时间,进而造成难以挽回的经济损失和资源浪费^[22-23]。由此可见,研究如何准确地对分布不平衡的机械设备健康状态数据进行分类具有重要意义。

迄今为止,解决不平衡分类问题的策略可以分为数据层面和算法层面两大类^[24]。数据层面的方法是改变训练集样本分布,降低不平衡程度;算法层面的方法考虑不同误分类情况代价的差异性对算法进行优化,使得该算法在不平衡数据下也能有较好的效果。Chawla等^[25]利用改进的合成少数类过采样技术(synthetic minority oversampling technique adaBoost, SMOTEBoost)从少数类创建合成样本,间接地改变更新权重并补偿偏斜分布。

Jia等^[26]提出一种基于深度归一化卷积神经网络的机械设备智能故障诊断方法,为解决机械设备健康状态不平衡分类问题提供一种有效思路。但是,这两个层面的方法都存在一些问题:数据层面的方法会改变原始数据的分布,容易增加训练时间以及丢失重要样本信息;算法层面的方法需要预先定义成本权值或成本矩阵,难以准确地设置。此外,这些经典的算法在数据预处理或特征选择等方面需要大量的人工工作,不适用于大容量的数据集。

针对以上问题,本文提出一种基于代价敏感卷积神经网络(cost sensitive convolutional neural network, CSCNN)的智能故障诊断方法。该方法首先经过多层卷积和池化运算学习原始监测数据中的机械设备本征性能状态知识;其次通过全连接层将本征性能状态知识映射为机械设备健康状态;最后引入代价敏感损失函数,为多数类赋予较小的误分类代价,为少数类赋予较大的误分类代价,期望在取得较高的总体样本分类准确率的同时提高少数类样本的识别率。通过数据量不平衡的刀具和轴承数据集验证CSCNN的有效性;通过与常规方法的对比,验证CSCNN在机械故障数据不平衡分类中的优越性。

1 代价敏感故障识别模型

针对卷积神经网络(convolutional neural network, CNN)在处理不平衡数据时对多数类和少数类一视同仁的问题,本文提出一种对不平衡健康状态样本代价敏感的损失函数,并详细介绍基于该损失函数构建的CSCNN模型。

1.1 CNN及不平衡分类问题

CNN是一种具有深度结构的前馈神经网络,主要包含3层:卷积层、池化层、全连接层,用于完成特征学习和分类。由于本文的输入数据是一维的原始振动信号,因此仅对一维CNN作简要介绍。

由于振动信号是一维数据,本文采用一维卷积运算。令输入信号为 x ,其长度为 N ,卷积核的权值矩阵为 w_c ,则卷积并激活运算可表示如下:

$$X_j^l = \text{Relu}\left(\sum_{i \in N_i} X_i^{l-1} * W_{ij}^l + b_j^l\right) \quad (1)$$

式中: X_i^{l-1} 是第 $l-1$ 层的第 i 个特征段; W_{ij}^l 是第 $l-1$ 层的第 i 个特征段和第 l 层的第 j 个特征段之间的卷积核权值矩阵; b_j^l 是第 l 层的第 j 个特征段所对应的偏置项; $\text{Relu}(\cdot)$ 是激活函数。此外,在卷积层之后增加了Dropout操作,可以有效抑制过拟合。

在Dropout层之后为池化层,用于压缩卷积层信息以及防止过拟合,本文采用的最大池化运算可表示如下。

$$p_j^l = \max \{ x_{j \times k; (j+1) \times k}^{l-1} \} \tag{2}$$

式中: p_j^l 是池化运算中第 l 层的第 j 个神经元输出值; $\max \{ \}$ 是池化运算函数, 计算目标区域内的最大值; $x_{j \times k; (j+1) \times k}^{l-1}$ 是第 $l-1$ 层的第 j 个局部区域, 该区域内神经元段的长度为 k 。

网络经过多层卷积和池化运算后学习得到输入信号中所隐含的特征知识, 再经全连接层将学习到的特征知识映射到样本标签空间, 计算过程如下:

$$x^l = \text{Relu} \left(\sum x^{l-1} \mathbf{w}_f^l + b_f^l \right) \tag{3}$$

式中: x^{l-1} 是第 $l-1$ 层的输出值; $\mathbf{w}_f^l$ 是第 $l-1$ 层的和第 l 层之间的全连接权值矩阵; b_f^l 是第 l 层所对应的偏置项。

在不平衡数据分类过程中, 多数类样本丰富, 少数类样本稀少, 因此, 训练得到的分类器对于少数类样本的识别准确率很低。CNN 不能有效解决数据量不平衡的分类问题原因在于它的损失函数, CNN 使用的 softmax 交叉熵损失函数可表示如下:

$$L = - \sum_{j=1}^c l(y_i = c) \log(s_j) \tag{4}$$

$$s_j = \frac{e^{x_j}}{\sum_{k=1}^c e^{x_k}} \tag{5}$$

式中: x_j 为最后一层全连接层的第 j 个输出值; s_j 为最后一层全连接层的第 j 个输出值的概率; C 为最后一层全连接层输出的神经元个数; c 为实际健康状态; y_i 为网络输出的健康状态; $l(\cdot)$ 表示括号内等式成立则函数值为 1、否则为 0。

在训练过程中, softmax 交叉熵损失将不同健康状态的误分类视为同等重要, 每个类别误分类代价相同, 只能最大限度地降低总体样本误分类。但对于不平衡数据集而言, 由于少数类样本占比小, 对总体样本分类精度影响甚微, 多数类样本的识别率对于总体样本的识别率起决定性作用。因此, 多数类样本误分类对 CNN 的训练过程影响较大, 而少数类样本误分类在一定程度上被忽略, 这使得 CNN 倾向于提高多数类样本的准确识别, 导致对少数类样本进行错误分类。

1.2 代价敏感损失函数

在 1.1 节中, 本文分析了 CNN 在对不平衡数据进行分类时存在的问题。由于 CNN 在分类过程中没有考虑不同类别样本的数量, 每个类默认的误分类代价是相同的, 所以其对不平衡数据集中的少数类样本识别率较低。为解决该问题, 本文提出根据数据集中样本的不平衡比例设置样本误分类代价的方法, 使得 CNN 在训练过程中为少数类样本赋予更大的误分类代价, 为多数类样本赋予更小的误分类代价。因此, 本文提出一种代价敏感的损失函数来改进 CNN 网络, 期望在保证较高的总体样本

分类精度的基础上提高网络对少数类样本的识别率。

在本文方法中, 根据样本数据量的占比, 不同样本误分类代价可表示如下:

$$v_c = \frac{\max \{ n_c \}_{c=1}^C}{n_c} \tag{6}$$
$$n_c = \sum_{i=1}^Q l(y_i = c) \tag{7}$$

式中: Q 为样本总数; n_c 表示不同健康状态样本的数量, 反映数据集的不平衡分布。在式(6)中, 样本的误分类代价可以根据数据集分布的不平衡程度自适应地计算得出, 当数据集中不同健康状态的样本分布平衡时, $v_c = 1$ 。根据式(6), 可定义代价敏感损失函数为:

$$L_s(\theta) = - \sum_{j=1}^c v_c l(y_i = c) \log(s_j) \tag{8}$$

模型训练过程中, 使用随机梯度下降 (stochastic gradient descent, SGD) 算法对模型参数进行优化, 逐层更新参数 θ , 最小化 $L_s(\theta)$ 使得模型对少数类样本的识别率达到最高。

1.3 代价敏感卷积神经网络

由前面的介绍可知, CNN 在对平衡数据集分类的问题上表现出较高的性能, 但是却不适用于不平衡数据集分类的问题。因此, 本文提出一种代价敏感卷积神经网络 (CSCNN), 将代价敏感损失函数应用于 CNN 中, 替换其原有损失函数, 期望在保证样本总体分类精度的同时提高网络对于少数类样本的识别率。

CSCNN 的结构如图 1 所示, 卷积层、池化层、全连接层、输出层在图中分别以 C、P、FC、FO 表示。当一维振动信号输入网络后, CSCNN 首先利用卷积层 C1 学习特征, 其次利用池化层 P1 对 C1 层学习的特征降采样, 然后重复前两个操作学习到高阶特征; 接着 P2 输出的特征被压平成一个特征向量并输入 FC1, FC1、FC2、FO 用于识别不同样本所代表的健康状态; 最终在代价敏感损失函数的作用下调整样本误分类代价, 实现各类样本的准确分类。CSCNN 参数信息如表 1 所示。

表 1 代价敏感卷积神经网络结构说明
Table 1 Illustration of CSCNN structure

层名称	执行操作	参数大小
Input	振动信号输入	1 200×1×1
C1	卷积	5×1×1
P1	最大池化	4×1
C2	卷积	5×1×20
P2	最大池化	4×1
FC1	全连接	1 500×200
FC2	全连接	200×100
FO	输出	100×C




图 1 代价敏感卷积神经网络结构
Fig.1 The structure of CSCNN

2 实验研究与模型性能分析

为验证提出方法对不平衡数据集的分类效果,利用在不同性能状态下采集的硬质合金铣削刀具数据集以及XJTU-SY 轴承数据集进行不平衡分类实验。为验证本文方法在故障数据不平衡分类方面的有效性,进行本文方法与其他方法的不平衡分类对比实验。

2.1 刀具健康状态数据不平衡分类

1) 硬质合金铣削刀具数据介绍

本文所使用的刀具监测数据采集自大恒 VMC850 加工中心,实验所切削的工件材料为 45 钢,工件尺寸为 60 mm×60 mm×100 mm 或 60 mm×100 mm×100 mm,用于切削工件的刀具为 APMT 1135 Duracarb,运行的工况条件为:主轴转速 2 500 rpm,进给速度 200 mm/min,背吃刀量 2 mm。使用 PCB 356A15 三向加速度传感器采集机床主轴振动信号,实验设备布置如图 2 所示,三向加速度传感器布置于主轴上(径向为 Z、切向为 Y、轴向为 X)。




图 2 实验设备布置
Fig.2 The layout of experiment equipment

GB/T 16460-1996 中对立铣刀的磨损量测量进行了标准化推荐,图 3(a)、(b)所示分别为实验过程中刀具失效的两种形式:磨损与破损。用于验证所提方法的主轴振动监测数据,采样频率为 10 kHz,图 4 所示为刀具健康状态划分结果。由图 4(a)刀具全寿命周期内振动信号时域波形可以看出,刀具振动信号的幅值随着时间推移逐渐增大。图 4(b)为 3σ 准则^[1,21,27]划分刀具健康状态的结果。3σ 准则又称为拉依达准则,是统计学中判别异常的常用准则,先假设一组检测数据只含有随机误差,对其进行计算处理得到标准偏差,按一定概率确定一个区间(μ-3σ,μ+3σ),认为凡超过这个区间的误差,就不属于随机误差而是粗大误差。该方法应用在刀具数据的划分时,首先提取振动信号的均方根特征,然后根据均方根特征计算故障阈值 μ+3σ,其中 μ 和 σ 分别为均方根特征的均值和标准差,图 4(b)中实线为均方根特征曲线,虚线代表故障阈值,均方根特征开始大于故障阈值时,判定该时刻为刀具故障起始点。图 5(a)、(b)所示分别为故障起始点刀尖及主后刀面磨损的照片。




图 3 刀具的主要失效形式
Fig.3 The main failure patterns of tools

根据图 4 中划分的刀具健康状态,制作用于验证 CSCNN 的数据集。刀具数据集构成如表 2 所示,N、F 分别代表正常、故障两种健康状态;T1、T2、T3 分别表示相同工况下同一品牌的 3 把刀具;A、B、C 分别代表 3 种不平衡比的数据集,A 为平衡数据集,N、F 分别占比 50%。

采集到的原始数据为刀具的全寿命周期数据,在




图 4 刀具健康状态划分

Fig.4 The division of tool's health condition




图 5 故障起始点刀片照片

Fig.5 Tool's photos of the fault starting point

表 2 刀具数据集划分
Table 2 The division of tool dataset %

类型	数据集	健康状态	
		N	F
T1	A	50	50
	B	90	10
	C	95	5
T2	A	50	50
	B	90	10
	C	95	5
T3	A	50	50
	B	90	10
	C	95	5

在机械设备实际运行过程中,故障样本较之正常样本更难采集,因此,增加数据集 A 中正常样本的数量构成数据集 B、C,用于模拟不平衡数据集,B 中 N、F 分别占比 90%、10%,C 中 N、F 分别占比 95%、5%。上述每个数据集中均采取 75% 作为训练集,剩下 25% 作测试集的策略。

2) 刀具数据不平衡分类实验

实验中的模型参数设置如下。根据文献[26],设置卷积核长度为 5,池化长度为 4,数据批量大小为 256。在上述参数设置下进行模型训练与测试并探索不同不平衡比数据集对故障诊断结果的影响,每次实验重复 10 次,刀具数据集对所提方法的验证结果如表 3 所示。从表 3 中可以看出利用 CSCNN 对不平衡数据进行分类,即使不平衡比很大,也能够在保证较高的总体分类精度的前提下取得很高的少数类分类精度(即召回率),而在机械故障诊断领域,对于少数类的识别尤为重要,验证了所提方法处理不平衡数据的有效性。

表 3 刀具数据集验证结果
Table 3 The validation results of tool dataset

类型	数据集	CSCNN			CNN			MLP		
		精度	召回率	F1	精度	召回率	F1	精度	召回率	F1
T1	A	0.995 7	0.992 9	0.995 7	0.993 8	0.991 6	0.993 8	0.992 3	0.98 8	0.992 2
	B	0.997 3	0.996 1	0.986 8	0.969 1	0.671 0	0.735 0	0.930 9	0.339 1	0.386 9
	C	0.969 1	0.965 4	0.755 7	0.958 5	0.237 1	0.302 4	0.965 0	0.386 9	0.399 5
T2	A	0.995 9	0.998 1	0.995 9	0.996 0	0.996 2	0.996 0	0.992 8	0.992 8	0.992 8
	B	0.959 7	0.984 0	0.823 7	0.952 0	0.763 4	0.756 5	0.948 3	0.601 0	0.645 0
	C	0.966 3	0.986 9	0.747 0	0.964 4	0.519 7	0.585 2	0.962 8	0.487 6	0.476 5
T3	A	0.975 8	0.970 3	0.975 1	0.974 6	0.971 1	0.974 0	0.972 3	0.988 1	0.972 6
	B	0.984 3	0.972 5	0.926 0	0.968 3	0.738 7	0.817 0	0.961 1	0.697 8	0.766 8
	C	0.997 7	0.994 3	0.976 4	0.980 6	0.587 6	0.699 6	0.990 7	0.516 2	0.497 4

为进一步验证所提方法的优越性,将提出算法与两种不同的故障诊断方法进行对比实验。(1)为验证代价敏感损失函数对于不平衡分类的影响,将经典的 CNN 作为对比方法用于故障数据不平衡的分类。该方法为一维卷积神经网络,将原始振动信号输入网络进行刀具健康状态的识别。(2)为验证特征学习对于不平衡分类的有效性,将手动提取特征并利用多层感知器 (multi-layer perceptron, MLP) 进行故障诊断的方法与本文方法进行对比。首先提取 18 个常用特征,包括方差、均方根值、平均绝对值、峭度指标、裕度指标、波形指标、峰值指标、偏度系数、频域均值、频域方差和 8 个小波包变换的能量比特征,然后将提取的特征输入 MLP 进行状态识别。表 3 同样记录了对比方法的实验结果,由表 3 中数据可以看出,在数据平衡情况下(数据集 A),对比方法与本文方法的 3 种评价指标非常接近,说明 3 种方法在平衡数据集上均可以取得非常好的诊断效果。在对比方法 1 中,随着不平衡比例的增大,虽然能保持较高的整体样本分类精度,但其对于少数类样本的识别率和 F1 指标也逐渐下降,甚至达到 23.71% 和 0.302 4,表明该方法对于不平衡数据的分类能力很差,验证了提出的代价敏感损失函数对于机械故障数据不平衡分类的有效性。在对比方法 2 中,该方法对于少数类的识别精度以及 F1 指标同样随着不平衡比的增大而减小,而且对比方法 1 的整体性能优于对比方法 2,说明特征学习的方法可学习振动信号所隐含的深层次特征知识,较之手动提取特征的故障诊断方法更为有效。

2.2 滚动轴承健康状态数据不平衡分类

1) XJTU-SY 轴承数据集

为测试所提方法处理不平衡数据多分类问题的效果,采用 XJTU-SY 轴承数据集^[28]进行验证。该数据集由 3 种工况下共 15 个实验轴承水平及垂直方向振动信号构成,每个轴承两个测点所布传感器型号均为 PCB 352C33,采样频率为 25.6 kHz。本文选取该数据集中相同工况下不同故障类型的 3 个轴承数据,即工况为 2 400 rpm(40 Hz)/11 kN 的轴承 3_1、3_2、3_3,利用 2.1 节所述的 3σ 方法划分出 N(正常)、IF(内圈故障)、OF(外圈故障)、IBCOF(内圈、滚珠、保持架、外圈复合故障)4 种健康状态。

根据划分出的轴承健康状态,制作用于验证的数据集。轴承数据集构成如表 4 所示,A、B、C 分别代表 3 种不平衡状态,同一不平衡状态下轴承的 4 种健康状态对应的百分比为该类型数据在整体数据中所占比例,由表 4 可知,A 为平衡数据集,4 种健康状态分别占比 25%。设备在运行过程中,轴承正常工作数据较之故障数据容易获取,单一故障数据较之复合故障数据容易获取,因而在不平衡数据集 B、C 中依次降低其占比,模拟实际数据不

平衡状态,B、C 中 N、IF、OF、IBCOF 的不平衡比分别为 15:2:2:1、35:2:2:1。上述 3 个数据集中均采取 75% 作为训练集,剩下 25% 作测试集的策略。

表 4 轴承数据集划分
Table 4 The division of bearing dataset %

数据集	N	IF	OF	IBCOF
A	25	25	25	25
B	75	10	10	5
C	87.5	5	5	2.5

2) 轴承数据不平衡分类实验

在与前文相同的模型参数设置下训练模型,依旧从两个方面与前文所述两种方法对比,测试本文方法处理不平衡数据多分类的效果,XJTU-SY 轴承数据集对上述 3 种方法的验证结果如表 5 所示,平衡数据集 A 对 3 种方法验证结果的混淆矩阵如图 6 所示。由图 6 和表 5 可见,在数据平衡状态下 CSCNN 和 CNN 对数据的特征学习和故障分类结果相近,而手动提取特征并利用 MLP 分类的结果明显要差很多,说明相对于手动提取特征,特征学习的方法能取得更高的分类精度。

表 5 轴承数据集验证结果
Table 5 Validation results of bearing dataset

数据集	CSCNN		CNN		MLP	
	精度	F1	精度	F1	精度	F1
A	0.980 6	0.980 6	0.971 0	0.970 9	0.929 4	0.928 7
B	0.990 6	0.990 7	0.968 4	0.967 8	0.962 8	0.905 3
C	0.995 6	0.995 7	0.971 6	0.968 9	0.982 8	0.904 9




图 6 平衡数据集 A 分类混淆矩阵
Fig.6 Confusion matrix of balanced dataset A

为了更直观地观察 3 种方法对不平衡数据集中不同健康状态的分类结果,图 7 所示为不平衡数据集 B 的混淆矩阵。由图 7(a)~(c)可知,多数类健康状态更容易被识别,多数类健康状态占比 75% 的情况下,3 种方法均能对其达到 100% 的识别率。少数类健康状态中单一故障样本占比高,识别率相对较高;复合故障 IBCOF 样本最少,因此识别率较低,CSCNN、CNN、MLP 3 种方法对其识别率依次为 94%、66%、56%,表明两种对比方法在处理不平衡数据时均不适用。




图 7 不平衡数据集 B 分类混淆矩阵

Fig.7 Confusion matrix of imbalanced dataset B

数据集 C 模拟了数据高度不平衡状态,复合故障样本仅占比 2.5%,图 8 所示为数据集 C 对应的混淆矩阵。与数据集 B 的混淆矩阵相比,在复合故障样本减少的情况下,CNN 对其识别率由 66%降低到 31%,MLP 对其识别率由 56%降低到 46%,而 CSCNN 的代价敏感损失函数增加了少数类样本的误分类代价,因此识别率仍能达到 95%。这些结果验证了代价敏感损失函数处理数据高度不平衡数据的优势。

3 结 论

针对现有智能故障诊断方法在处理不平衡机械故障数据时存在少数类样本分类精度低的问题,本文提出一种基于代价敏感卷积神经网络的机械故障数据不平衡分类方法。本文方法首先经过多层卷积和池化运算学习原始监测数据中的机械设备本征性能状态知识;其次通过




图 8 不平衡数据集 C 分类混淆矩阵

Fig.8 Confusion matrix of imbalanced dataset C

全连接层将本征性能状态知识映射为机械设备健康状态;最后利用代价敏感损失函数为少数类样本赋予较大的误分类代价,为多数类样本赋予较小的误分类代价,实现机械故障数据不平衡的有效分类。本文方法通过刀具和轴承数据进行验证,并与两种方法进行对比。由实验结果可知:1) 本文方法为多数类和少数类样本赋予不同的误分类代价,使得网络在训练过程中对于少数类样本更为敏感,在保证了总体分类精度的前提下提高了少数类识别精度;2) 相对于手动提取特征,特征学习方法取得了更好的故障诊断准确率。上述实验与结论表明本文方法可一定程度解决故障样本匮乏条件下机械故障数据不平衡分类的问题,这为智能故障诊断方法的工业化应用提供了一种潜在可行的方案。

参考文献

[1] 史庆军,郭晓振,刘德胜.基于特征量融合和支持向量机的轴承故障诊断[J].电子测量与仪器学报,2019,33(10):104-111.
SHI Q J, GUO X ZH, LIU D SH. Bearing fault diagnosis based on feature fusion and support vector machine[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(10):104-111.

[2] 余兢克,薛时雨,孙培伟,等.基于深度学习的核电站事故预测及故障诊断方法[J].仪器仪表用户,2019,26(12):39-44.
SHE J K, XUE SH Y, SUN P W. The application of lstm model to the prediction of abnormal operation in nuclear

- power plants [J]. Instrumentation, 2019, 26 (12): 39-44.
- [3] GUO L, GAO H L, HUANG H F, et al. Multifeatures fusion and nonlinear dimension reduction for intelligent bearing condition monitoring[J]. Shock and Vibration, 2016;1-10.
- [4] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
- LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era[J]. Journal of Mechanical Engineering, 2018, 54(5): 94-104.
- [5] GUO L, LEI Y G, LI N P, et al. Deep convolution feature learning for health indicator construction of bearings [J]. 2017 Prognostics and System Health Management Conference (PHM) , , 2017, DOI: 10. 1109/PHM.2017. 8079167.
- [6] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946-1953.
- ZHAO G Q, GE Q Q, LIU X Y, et al. Research on fault feature extraction and diagnosis method based on DBN[J]. Chinese Journal of Scientific Instrument, 2016, 37(9): 1946-1953.
- [7] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
- QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.
- [8] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [9] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. Proceedings of the IEEE conference on computer vision and pattern recognition, 2016: 770-778.
- [10] 陶聪, 施云, 张丽艳. 基于卷积神经网络的汉字编码标记点检测识别 [J]. 仪器仪表学报, 2019, 40 (8): 191-200.
- TAO C, SHI Y, ZHANG L Y. Detection and recognition of Chinese character coded marks based on convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 191-200.
- [11] 郑啸, 王义真, 袁志祥, 等. 基于卷积记忆神经网络的微博短文本情感分析[J]. 电子测量与仪器学报, 2018, 32(3):195-200.
- ZHENG X, WANG Y ZH, YUAN ZH X. Sentiment analysis of micro-blog short text based on convolutional memory neural network[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(3):195-200.
- [12] 李响, 李国正, 石俊刚, 等. 基于语音心理学分析的驾驶疲劳检测 [J]. 仪器仪表学报, 2018, 39 (10): 166-175.
- LI X, LI G ZH, SHI J G, et al. Fatigue driving detection based on speech psychoacoustic analysis [J]. Chinese Journal of Scientific Instrument, 2018, 39(10):166-175.
- [13] TANG Y CH, ZHANG Y Q, NITESH V C, et al. SVMs modeling for highly imbalanced classification, IEEE, 2009, 39: 281-288.
- [14] JING L Y, ZHAO M, LI P, et al. A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox [J]. Measurement, 2017, 111: 1-10.
- [15] 张伟. 基于卷积神经网络的轴承故障诊断算法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2017.
- ZHANG W. Research on bearing fault diagnosis algorithm based on convolutional Neural Network [D]. Harbin: Harbin Institute of Technology, 2017.
- [16] JIA F, LEI Y G, GUO L, et al, A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines, Neurocomputing, 2018, 272: 619-628.
- [17] 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 Trans. Ind. Electron., 2018, 66(9):7316-7325.
- [18] ZHANG L, GAO H L, WEN J, et al. A deep learning-based recognition method for degradation monitoring of ball screw with multi-sensor data fusion [J]. Microelectronics Reliability, 2017, 75: 215-222.
- [19] ZHANG L, GAO H L, DONG D W, et al. Wear calculation based degradation analysis and modeling for remaining useful life prediction of ball screw [J]. Mathematical Problems in Engineering, 2018:1-18.
- [20] GUO L, LI N P, JIA F, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. Neurocomputing, 2017, 240: 98-109.
- [21] GUO L, LEI Y G, LI N P, et al. Machinery health indicator construction based on convolutional neural networks considering trend burr [J]. Neurocomputing, 2018:1-9.
- [22] JANUSZ A, GRZEGOROWSKI M, MICHALAK M,

- et al. Predicting seismic events in coal mines based on underground sensor measurements [J]. Engineering Applications of Artificial Intelligence, 2017, 64:83-94.
- [23] 包萍,刘运节.不平衡数据集下基于生成对抗网络的改进深度模型故障识别研究[J].电子测量与仪器学报, 2019,33(3):176-183.
- BAO P, LIU Y J. Research on fault identification based on improved deep model in combination of generative adversarial networks under unbalanced data sets [J]. Journal of Electronic Measurement and Instrumentation, 2019,33(3):176-183.
- [24] 吴一全,殷骏,戴一冕,等.基于蜂群优化多核支持向量机的淡水鱼种类识别[J].农业工程学报, 2014, 30(16):312-319.
- WU Y Q, YIN J, DAI Y M, et al. Identification of freshwater fish species based on bee colony optimization multi-core support vector machine [J]. Journal of Agricultural Engineering, 2014, 30 (16):312-319.
- [25] CHAWLA N V, LAZAREVIC A, HALL L O, et al. SMOTEBoost: Improving prediction of the minority class in boosting [J]. Lecture Notes in Computer Science, 2003:107-119.
- [26] JIA F, LEI Y G, LI N P, 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.
- [27] LI N P, LEI Y G, LIN J, et al. An improved exponential model for predicting remaining useful life of rolling

element bearings [J]. IEEE Transactions on Industrial Electronics, 2015, 62(12):1-1.

- [28] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings [J]. IEEE Transactions on Reliability, 2018:1-12.

作者简介



董勋, 2018 年于南通大学获得学士学位,现为西南交通大学硕士研究生,主要研究方向为机械设备故障诊断。

E-mail: dong_x@my.swjtu.edu.cn

Dong Xun received his B.Sc. degree from Nantong University in 2018. He is currently a M.Sc. candidate at Southwest Jiaotong University. His main research interests include mechanical equipment fault diagnosis.



郭亮 (通信作者), 分别于 2011 年和 2016 年在西南交通大学获得学士和博士学位。2016 年~2018 年在西安交通大学进行博士后研究工作。主要研究方向为机械设备智能故障诊断和剩余寿命预测。

E-mail: guoliang@swjtu.edu.cn

Guo Liang (Corresponding author) received his B. Sc. degree and Ph. D. degree in Mechanical Engineering from Southwest Jiaotong University in 2011 and 2016, respectively. He was a Postdoctoral research fellow at Xi'an Jiaotong University from 2016 to 2018. Now, He is currently an assistant professor at Southwest Jiaotong University. His research interests include machinery intelligent fault diagnostics, and remaining useful life prediction.