

并行网络与数据扩充方法在乘用车异响识别中的应用*

陈达亮¹ 张博文² 郝耀东¹ 安子军² 邓江华¹

(1.中汽研(天津)汽车工程研究院有限公司,天津 300399;2.燕山大学,秦皇岛 066000)

【摘要】针对乘用车车内异响识别研究过程中数据集少且人工诊断法效率低的问题,提出了一种具有高识别准确率的数据扩充方法,并采取卷积神经网络与Transformer编码器栈并行的工作机制获得分类模型。结果表明,当将提取的扩充数据的梅尔倒谱系数特征用作并行网络的输入时,所提出的数据扩充方法可有效提高分类性能,且拟议模型在测试集上可以实现高达98.31%的分类精度。

关键词:异响识别 卷积神经网络 Transformer编码器栈 并行网络 音频剪切 数据增强
中图分类号:U461.4 文献标识码:A DOI: 10.19620/j.cnki.1000-3703.20220196

Application of Data Expansion Method and Parallel Network in Abnormal Noise Recognition for Passenger Vehicles

Chen Daliang¹, Zhang Bowen², Hao Yaodong¹, An Zijun², Deng Jianghua¹

(1. CATARC (Tianjin) Automotive Engineering Research Institute Co., Ltd., Tianjin 300399; 2. Yanshan University, Qinhuangdao 066000)

【Abstract】To address the problems of small dataset and low efficiency of artificial diagnosis method in the research process of passenger vehicle abnormal noise recognition, this paper proposed an efficient intelligent recognition technique, which applied data expansion method with high recognition accuracy and adopted the parallel working mechanism of Convolutional Neural Network (CNN) and Transformer encoder stack to obtain the classification model. It is found that the data expansion method can effectively improve the classification performance when the extracted Mel Frequency Cepstral Coefficients (MFCCs) features of the augmented data are used as the input to the parallel network, and the proposed model can achieve classification accuracy up to 98.31% on the testing dataset.

Key words: Abnormal noise recognition, Convolutional Neural Networks(CNN), Transformer encoder stack, Parallel network, Audio clip, Data augmentation

【引用格式】陈达亮,张博文,郝耀东,等.并行网络与数据扩充方法在乘用车异响识别中的应用[J].汽车技术,2023(5):1-7.

CHEN D L, ZHANG B W, HAO Y D, et al. Application of Data Expansion Method and Parallel Network in Abnormal Noise Recognition for Passenger Vehicles[J]. Automobile Technology, 2023(5): 1-7.

1 前言

目前,基于各种信号的故障诊断技术已广泛应用于工业生产中,但针对乘用车系统中存在的异响问题,相关数据集的匮乏限制了该领域诊断技术的发展,因此有必要进行基于易获信号的车辆异响诊断方法开发。

在故障诊断领域,研究人员采用梅尔频率倒谱系数(Mel Frequency Cepstral Coefficients, MFCCs)特征^[1]和小波特征^[2]等作为声信号特征输入分类器,分类器利用自

身的数据统计分析能力,最终实现分类功能。分类器可分为2个阶段,即传统机器学习阶段和深度学习阶段。前者代表算法有支持向量机^[3]、决策树^[4]和人工神经网络^[5]等;后者代表算法有卷积神经网络(Convolutional Neural Network, CNN)^[6]、循环神经网络(Recurrent Neural Network, RNN)^[7]等。

在传统机器学习方面:文献[8]针对旋转机械出现的早期故障振动信号,进行了小波包分解和经典模式分解以获得故障特征,并在机械轴承上得到试验验证;文

*基金项目:中国汽车技术研究中心有限公司指南项目(21233405)。

献[9]利用小波基函数逐级对轴承故障特征进行小波包分解,最终实现了超过99%的分类精度。

在深度学习方面:文献[10]开发了一种车辆动力总成系统异响的分类方法,提取了MFCCs特征作为RNN的输入,最终实现了87.6%的分类精度;文献[11]使用了2种数据增强方法,并利用含有残差链接的CNN开发了针对旋转机械的故障诊断技术,最终在公开数据集上实现了99.91%的识别率。

传统机器学习和深度学习在分类问题上都存在一些不足:前者在分析处理复杂函数或庞大数据时计算能力不足,不适合智能分类领域的发展趋势;后者在数据集小且稀疏的情况下极易造成深度学习模型过拟合现象。本文基于有限的7种异响数据,并利用数据扩充方法增加样本数量,提出一种新的深度学习识别方法,验证Transformer编码器栈和CNN并行工作机制的有效性,同时提取输入特征的空间和时序信息以获得更高的识别精度。

2 数据处理与特征提取

2.1 异响数据处理

本文利用HeadLab前端设备进行若干车型的车内噪声数据采集,为了降低训练风险并保留声音信号的完整信息,统一采样频率为48 kHz,量化位数为16 bit。对噪声数据进行人工听诊作为初步主观筛选,利用Testlab对噪声数据进行时域和频域分析作为客观筛选,综合主、客观筛选结果并截取异常噪声的出现时间段,最终作为有效数据保留。为验证诊断模型的泛化能力,将有效数据以8:1:1的比例划分为训练集、验证集和测试集,其中训练集和验证集的数据集合统称为训练数据,测试集为测试数据。

2.2 数据扩充方法

划分数据集后,针对各数据集分别采用音频剪切和数据增强方式来扩充数据。

2.2.1 音频剪切

将一段音频切成若干个小时时间块,通过分析该段音频波形图,确定异常频率之间的时间间隔。本文确定小时时间块的时长为3 s,为避免裁剪过程中相邻时间块出现信息丢失,设置切分步长为2 s。

2.2.2 数据增强

采用4种有效方法进行数据增强,分别是时间拉伸(Time Stretching)、时间平移(Time Shifting)、噪声增加(Noise Addition)、音高修正(Pitch Shifting)。

2.2.2.1 时间拉伸

在音高不变的前提下,通过设置拉伸参数 v 改变原音频信号的速度, $v \in (1, +\infty)$ 或 $v \in (0, 1)$ 表示加快或减慢音

频速率为原音频速率的 v 倍。为了防止音频失真,本文对每个音频数据设置了一组拉伸参数 $v \in [0.8, 2]$ 。

2.2.2.2 时间平移

保持音高不变,在时域范围平移一定距离,平移参数 σ 可设置为正值或负值,分别代表音频数据向前或向后平移。本文对每个音频数据设置平移参数 $\sigma = f_s/2$,其中 f_s 为采样频率,本文取 $\sigma \in \{-f_s/2, f_s/2\}$ 。

2.2.2.3 噪声增加

噪声增加是自然语言处理和图像识别领域常用的增强技术,在声音识别领域,噪声增加是指为原音频数据增加背景噪声,如高斯噪声、环境音等。本文选择添加均值为0,标准差为1的高斯白噪声。


2.2.2.4 音高修正

在音速不变的前提下,改变原音频的音高,实际上音高的改变并不影响故障特征的标签,通过设置修正参数 ρ 使音高向上或向下移动若干步(以半音为单位, ρ 为正代表向上移,反之向下),本文取 $\rho \in \{-6, 3, 6\}$ 。


所有的异响类型、样本量、时长及数据扩充后的数据信息如表1所示。图1所示为4种增强技术的部分处理结果,原始音频是一段经过筛选的减速器敲击声。

表1 数据信息

异响类型	样本量/个	总时长/s	时间块/个	扩充时间块/个
齿轮啸叫	49	535	245	1 960
减速器 敲击	21	481	231	1 848
齿轮冲击	36	534	252	2 016
阀门系统	43	555	258	2 064
手扶箱	58	635	290	2 320
手套箱	61	598	281	2 248
座椅	61	671	305	2 440
总计	329	4 009	1 862	14 896



(a)原始音频



(b)时间拉伸($v=2$)

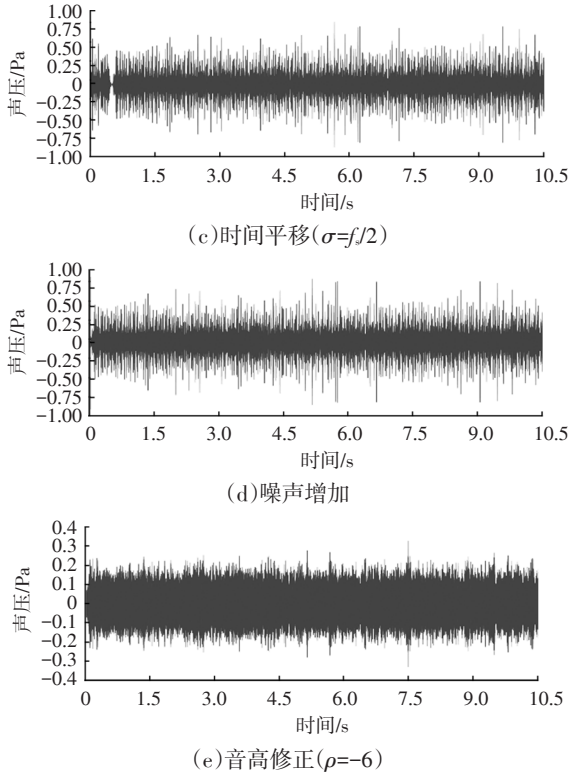


图1 增强信号与原始信号波形对比

2.3 特征提取

为了获取有效的故障诊断特征及可以用于深度学习的输入数据,提取基于对数滤波器组能量(Logfbank)及MFCCs的特征参数,提取流程如图2所示。




图2 特征提取流程

具体操作过程如下:

a. 预加重。噪声数据通过预加重达到平衡频谱和改善信噪比的目的,图3所示为一段原始敲击噪声,预加重结果如图4所示。时域信号 $X(n)$ 预加重后的输出为:

$$X'(n)=X(n)-\alpha X(n-1) \quad (1)$$

式中, n 为采样点序号; α 为滤波器系数。




图3 减速器敲击异响




图4 经预加重的减速器敲击异响

b. 分帧、加窗。使用汉明窗将信号分为若干短的时间段,每个短时间段称为分析帧,可认为在分析帧内,信号的频率平稳。为了保持信号的连续性,避免信号失真,相邻的分析帧通常会有重叠,重叠部分称为帧移。分帧操作可表达为:

$$X'_i(n)=\omega(n)\cdot X(n) \quad (2)$$

其中, $\omega(n)$ 为汉明窗函数:

$$\omega(n)=0.54-0.46[2\pi n/(N-1)], 0\leq n\leq N-1 \quad (3)$$

式中, $X'_i(n)$ 为分帧后第 i 帧信号; N 为窗口长度。

c. 傅里叶变换与功率谱计算。在每个分析帧上进行傅里叶变换,将时域信号转换为频域功率分布,然后计算功率谱:

$$P_i(k)=\left|\sum_{n=1}^N X'_i(n)\cdot\omega(n)e^{-j2\pi kn/N}\right|^2/N, 1\leq k\leq K \quad (4)$$

式中, $P_i(k)$ 为第 i 帧对应的第 k 个功率谱; j 为傅里叶变换时的虚部单位; K 为傅里叶变换的长度。

d. 梅尔滤波器组滤波。功率谱经过梅尔尺度的三角滤波器组便可以得到人耳感知频率范围内的音频。音频的实际频率 f 与梅尔尺度频率 $Mel(f)$ 的关系为:

$$Mel(f)=1125\ln(1+f/700) \quad (5)$$

e. 对数能量分析。对每个滤波器的输出取对数得到对数能量,将滤波器组输出的对数能量命名为Logfbank,对数能量输出为:

$$P_{\log}(m)=\ln\left(\sum_{k=0}^{N-1} P_i(k)H_m(k)\right), 0\leq m\leq M \quad (6)$$

其中, $H_m(k)$ 为三角滤波器组的定义函数:

$$H_m(k)=\begin{cases} \frac{k-f(m-1)}{f(m)-f(m-1)}, & f(m-1)\leq k\leq f(m) \\ \frac{f(m+1)-k}{f(m+1)-f(m)}, & f(m)\leq k\leq f(m+1) \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中, M 为滤波器数量; $f(m)$ 为第 m 个滤波器的中心频率。

f. 离散余弦变换。去除Logfbank特征之间的高度相关性以获得更为抽象的特征(MFCCs):

$$C(n')=\sum_{m=0}^{N-1} P_{\log}(m)\cos\left(\frac{\pi n'(m-0.5)}{M}\right), 0\leq n'\leq M \quad (8)$$

式中, n' 为MFCCs的阶数。

2.4 特征形状

基于Pytorch框架(版本1.7.0),对训练数据和测试数据应用5种数据扩充方法后,利用Python_speech_feature库中的Logfbank函数提取Logfbank特征,利用Librosa库中的Librosa.feature.mfcc函数提取MFCCs特征。函数设置细节如表2所示,特征形状为本文拟议并行架构的输入形状(特征阶数×时间的2维矩阵)。

表2 特征提取细节

特征类型	函数关键参数细节	特征形状
Logfbank	logfbank(sr=48k,winlen=0.01ms,winstep=0.005,nfilt=40,nfft=1024,preemph=0.97>window=hamming)	40×282
MFCCs	librosa.feature.mfcc(sr=48k,n_mfcc=40,n_fft=1024,winlen=512,hop_length=256>window='hamming',n_mel=128)	40×282

3 深度学习

3.1 卷积神经网络

卷积神经网络目前仍然是计算机视觉领域的主流方法,原因在于它可以共享权重参数,且可以相对少的权值参数建立稀疏联系^[12]。以上特点使得网络更易于优化,同时降低了过拟合的风险。

卷积网络由若干典型层组成,典型层中一般包含卷积层和池化层,其中卷积层通过使用微型卷积核与输入张量进行卷积运算,从而实现局部信息的扫描,同时还需要采用非线性激活函数(一般使用线性整流函数(Rectified Linear Unit, ReLU))加快特征学习能力。池化层则用于提取重要的局部信息,提高计算效率,一般使用最大池化或平均池化。最后经过全连接层实现分类功能。图5展示了含有1个典型层和2个全连接层的简化CNN结构。




图5 简化的CNN结构

3.2 Transformer 编码器

Transformer 目前已成为主流的序列到序列(Seq2Seq)模型。其利用由若干编码器串联而成的编码器栈取代了以RNN为核心的编码器。如图6所示,编码器栈中的每一个编码器由多头注意力(Multi-Head Attention, MHA)单元和前馈神经网络单元串联而成,每一个单元又附有残差连接。加入残差连接的原因

在于:参数的分布在训练时可能不断变化,残差连接可以使网络对特征参数进行归一化操作,从而能够学习到更有效的梯度。

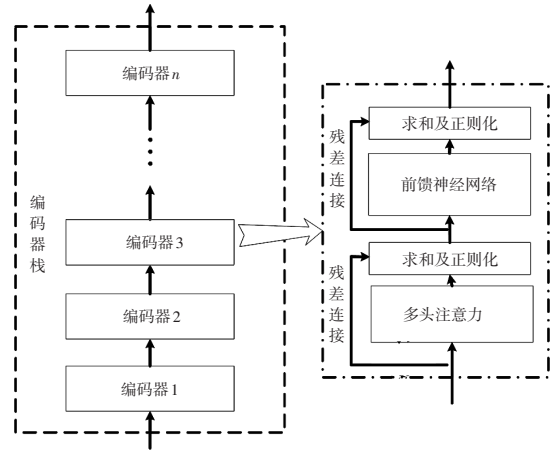


图6 编码器栈结构

3.2.1 多头注意力机制

注意力机制将输入的上下文序列向量映射为数字张量集合 $\{k_i, v_i\}$,通过 $Softmax$ 函数使输入矩阵 Q 和键矩阵 K 的相似度呈概率分布,然后与值矩阵 V 进行加权求和,最终映射为 Z 值并作为前馈神经网络单元的输入。

MHA可以理解成若干基于缩放的点乘注意力(Scaled Dot-product Attention, SDA)并行的形式。SDA映射函数表示为:

$$A_{SDA}(Q, K, V) = S\left(\frac{QK^T}{\sqrt{D}}\right)V \quad (9)$$

式中, D 为 Q 或 K 的矩阵维度,当 $Q=K=V$ 时称为自注意力; $S()$ 为概率化函数。

进一步,MHA可表示为:

$$H_i = A_{SDA}(QW_i^Q, KW_i^K, VW_i^V) \quad (10)$$

$$H_{concat} = [H_1 H_2 \dots H_h] \quad (11)$$

$$A_{MHA}(Q, K, V) = H_{concat} \cdot W_i^O \quad (12)$$

式中, H_i 为第 i 个映射矩阵; H_{concat} 为映射矩阵集合; h 为MHA的“头数”; $W_i^Q, W_i^K, W_i^V, W_i^O$ 为训练学习的权重参数。

3.2.2 求和与正则化

残差连接借用残差网络(ResNet)^[13]的思想,通过求和(Add)形式实现,目的是避免多层叠加网络导致的梯度消失和爆炸问题。加入正则化(Norm)操作是对张量进行归一化,从而达到降低学习难度的目的。最终残差连接的输出表示为: $LN(x+Sub(x))$ 。其中, x 为输入的恒等映射, $Sub(x)$ 代表网络单元对 x 的激活映射, $LN()$ 为归一化操作,其具体输出表示为:

$$O = \frac{x - M_{axis}(x)}{\sqrt{Var(x) + \varepsilon}} \omega + b \quad (13)$$

式中, $M_{axis}(x)$ 、 $Var(x)$ 分别为给定通道轴的平均值和方差; ε 为避免分母为0的参数; ω 、 b 分别为可学习的权重与偏置项。

3.2.3 前馈神经网络

前馈神经网络也称为全连接神经网络,一般包括输入层、隐含层和输出层。在Transformer中,其输入层为编码器在经过第1个归一化处理后的输出张量。具体传播形式为:

$$a^{(l)} = f_i(W^{(l)} \cdot a^{(l-1)} + b^{(l)}) \quad (14)$$

式中, $a^{(l)}$ 为第 l 层的输出; $f_i()$ 为激活函数; $W^{(l)}$ 、 $b^{(l)}$ 分别为第 l 层所使用的权重和偏置。

4 并行网络诊断架构

卷积神经网络针对复杂的输入特征,通过正、反向传播,使输出尽可能逼近一个能匹配信号特征的非线性函数,得到输入特征在空间尺度的信息。Transformer编码器通过多头注意力机制加上残差连接捕获连续信号各时序之间的隐藏关系,从而得到输入连续特征的时序信息。为了提高诊断模型的诊断能力,同时获取信号的空间信息和时序关系信息,本文设置了深度卷积网络和Transformer编码器栈同时工作的架构来提高诊断性能。

图7展示了拟议架构,在架构中,设置了2条用于提取空间信息的并行CNN线路(CNN1、CNN2)和1条用于提取时序信息的编码器栈线路(Transformer)。对于输入的2D特征,在CNN1中设置了3个卷积层,采用 3×3 的微型卷积核,在CNN2中同样设置3个卷积层,与CNN1不同的是,用 3×1 和 1×3 的非对称卷积核取代了 3×3 卷积核,这不仅极大减少了计算参数,而且可以获得额外的空间信息。另外,每个卷积层最后均设有池化操作用于减少参数数量、加快训练速度。在Transformer中,首先对输入的特征图进行池化,然后采用串联Transformer编码器栈进行时序信息抓取。最终将3条并行线路提取到的空间时序信息融合,再线性变换到全连接层,最后使用Softmax函数输出各噪声类型的概率。并行线路可以实现CNN与Transformer协同工作,避免了深层网络带来的计算成本。

表3展示了并行架构的细节, (a, b, c, d) 表示卷积层/池化层卷积核/池化核数量为 a ,卷积核/池化核宽、高、步长分别为 b, c, d , Dropout(0.4)表示随机丢弃40%的神

经元, $5 \times ()$ 表示5个编码器, MHA(5)表示多头注意力包含5个自注意力。网络加入了批量归一化(Batch Normalization, BN)层,这对网络训练效率和优化梯度问题有明显的增益^[4]。对于反向传播中的梯度问题,选取了随机梯度下降(Stochastic Gradient Descent, SGD)优化技术,SGD中的优化参数设置为:学习率为0.01、权重衰退系数为0.001、动量为0.8。此外,在卷积层中,为了避免丢失特征图中的边缘信息,统一采用零填充卷积。而在每个卷积层的池化级之后,均采用了随机失活(Dropout)技术,这种技术通过随机丢弃参数来避免模型因过拟合带来的泛化能力差的问题。另外,交叉熵损失函数用于计算网络成本。




图7 并行架构

表3 并行架构细节

线路	架构细节
CNN1	Conv2D(16,3,3,1)-BN-ReLU-MaxPool(16,2,2,2)-Dropout(0.4)-Conv2D(32,3,3,1)-BN-ReLU-MaxPool(32,4,4,4)-Dropout(0.4)-Conv2D(64,3,3,1)-BN-ReLU-MaxPool(64,4,4,4)-Dropout(0.4)
CNN2	Conv2D(16,1,3,1)-BN-ReLU-MaxPool(16,2,2,2)-Dropout(0.4)-Conv2D(32,3,1,1)-BN-ReLU-MaxPool(32,4,4,4)-Dropout(0.4)-Conv2D(64,1,3,1)-BN-ReLU-MaxPool(64,4,4,4)-Dropout(0.4)
Transformer	MaxPool(1×4,1×4)-Embedding-5×(MHA(5)-Dropout(0.4)-LN-Linear-Dropout(0.4)-Linear-Dropout(0.4)-LN)

5 并行网络性能评估

5.1 异响识别试验流程

异响识别整体流程如图8所示,为了保证网络后期训练的准确性,数据扩充设置在划分数据集之后,以避免来自同一原始音频的扩充数据同时分布到训练集、验证集和测试集中。

5.2 仿真实验验证

将应用了5种扩充技术的各数据集与原始数据集合在一起作为最终的扩充数据集,并提取MFCCs特征作为输入。

提取Logfbank作为网络输入用于对比,试验设置与3.2.1节类似。结果如图9所示:所提出方法的4项评价指标准确度、精度、召回率和F1分数均明显高于以Logfbank作为输入特征时的结果,分别达到0.983 1、

0.976 0、0.982 4、0.978 7。

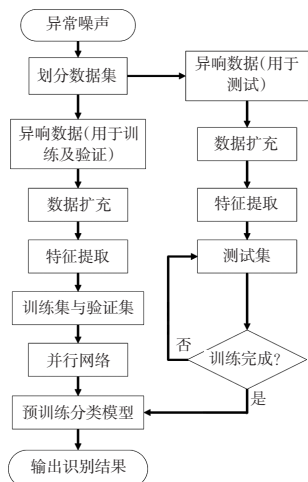


图8 异响识别整体流程

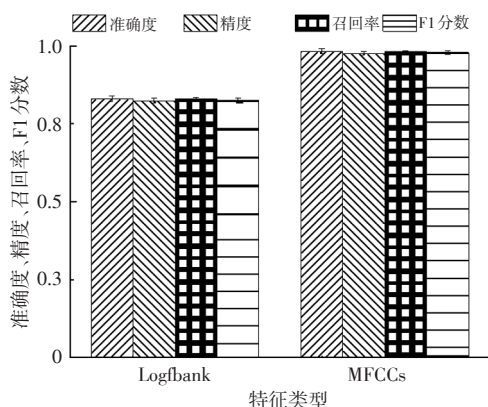


图9 不同特征的性能比较

以MFCCs特征作为输入,将本文提出的模型与其他主流模型进行对比,对比模型包括支持向量机(Support Vector Machine, SVM)、VGG16^[15]和长短期记忆(Long Short-Term Memory, LSTM)网络。其中SVM不能直接处理二维输入特征,因此在时间维度上进行了降维处理(在时间维度上取均值),并采用高斯核函数(Radial Basis Function, RBF),惩罚因子参数设置为1;共设置3层,其中LSTM层设置64个隐藏单元。测试精度结果如图10所示。

从图10中可以看出:采用扩充技术所获得的扩充数据作为输入明显能够获得更优的仿真结果。其中,针对本研究任务,拟议识别模型在3种深度学习模型中最优,而随着扩充数据集的加入,SVM模型诊断性能下降,原因在于:数据量的大幅提升会增加分类器的计算负荷,极易造成性能不稳定;所使用的扩充数据集本身是由少量原始数据增广而来,不同类型的噪声经过数据扩充后降低了原本的稀疏性(如减速度器敲击和齿轮冲击经过加噪后波形图表现相似),从而使得分类器的性能下降。因此SVM更擅长处理小而稀疏的数据集,但这

并不符合基于大数据诊断模型开发的发展趋势。




图10 不同识别模型在各数据集上的表现

6 结束语

本文基于新的深度学习并行架构,并使用数据扩充技术,提出了一种用于车辆异响识别的方法。试验验证了所提出方法的分类性能,并探究了以2种常用的说明性特征(MFCCs与Logbank)作为输入时对识别性能的影响,进一步对比了拟议方法与其他3种识别模型的性能,结果表明:所提出的方法在包含7种车辆异响的扩充数据集上可以实现98.31%的识别精度;MFCCs特征更适用于所提出的并行网络架构;异响数据应用数据扩充技术结合深度学习可有效提高识别性能。另外,所提出的方法明显优于另外3种流行的识别模型,可供乘用车售后服务平台以及车辆异响识别的算法研究参考。

参考文献

- [1] 王昱翔, 殷希梅, 陈凯, 等. 车辆发动机异响信号的故障特征参数提取方法[J]. 兵器装备工程学报, 2020, 41(2): 44-48.
WANG Y X, YIN X M, CHEN K, et al. Fault Feature Parameter Extraction Method for Abnormal Sound of Vehicle Engine[J]. Journal of Ordnance Equipment Engineering, 2020, 41(2): 44-48.
- [2] MURALIDHARAN V, SUGUMARAN V. Rough Set Based Rule Learning and Fuzzy Classification of Wavelet Features for Fault Diagnosis of Monoblock Centrifugal Pump[J]. Measurement, 2013, 46(9): 3057-3063.
- [3] CHANG C C, LIN C J. LIBSVM: A Library for Support Vector Machines[J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 1-27.
- [4] MURALIDHARAN V, SUGUMARAN V. Feature Extraction Using Wavelets and Classification through Decision Tree Algorithm for Fault Diagnosis of Mono-Block Centrifugal Pump[J]. Measurement, 2013, 46(1): 353-359.
- [5] TIAN Z G. An Artificial Neural Network Method for Remaining Useful Life Prediction of Equipment Subject to

- Condition Monitoring[J]. Journal of Intelligent Manufacturing, 2012, 23(2): 227-237.
- [6] ZEILER M D, FERGUS R. Visualizing and Understanding Convolutional Networks[J]. Lecture Notes in Computer Science, 2014, 8689: 818-833.
- [7] SUN L, DU J, DAI L R, et al. Multiple-Target Deep Learning for LSTM-RNN Based Speech Enhancement[C]// 2017 Hands-Free Speech Communications and Microphone Arrays (HSCMA). San Francisco, CA, USA: IEEE, 2017: 136-140.
- [8] BIN G F, GAO J J, LI X J, et al. Early Fault Diagnosis of Rotating Machinery Based on Wavelet Packets—Empirical Mode Decomposition Feature Extraction and Neural Network [J]. Mechanical Systems and Signal Processing, 2012, 27: 696-711.
- [9] 夏田, 詹瑶, 郭建斌. 基于小波包和梯度提升决策树的轴承故障诊断[J]. 陕西科技大学学报, 2020, 38(5): 144-149.
- XIA T, ZHAN Y, GUO J B. Bearing Fault Diagnosis Based on Wavelet Packet and Gradient Boosting Decision Tree[J]. Journal of Shaanxi University of Science, 2020, 38(5): 144-149.
- [10] JUNG I, LEE D, YOO D, et al. A Diagnostic Technology of Powertrain Parts that Cause Abnormal Noises Using Artificial Intelligence[J]. SAE Technical Paper, 2020-01-1565, 2020.
- [11] LI X, ZHANG W, DING Q, et al. Intelligent Rotating Machinery Fault Diagnosis Based on Deep Learning Using Data Augmentation[J]. Journal of Intelligent Manufacturing, 2020, 31(2): 433-452.
- [12] 胡涛, 张超, 程炳, 等. 卷积神经网络在异常声音识别中的研究[J]. 信号处理, 2018, 34(3): 357-367.
- HU T, ZHANG C, CHENG B, et al. Research on Abnormal Audio Event Detection Based on Convolutional Neural Networks[J]. Journal of Signal Processing, 2018, 34(3): 357-367.
- [13] 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 (CVPR). Vegas, NV, USA: IEEE, 2016.
- [14] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift[EB/OL]. (2015-03-02)[2021-06-18]. <https://arxiv.org/abs/1502.03167>.
- [15] SIMONYAN K, ZISSERMAN A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. (2015-04-10)[2021-06-15]. <https://arxiv.org/abs/1409.1556>.

(责任编辑 斛 畔)

修改稿收到日期为2022年4月12日。

《汽车技术》征稿启事

《汽车技术》杂志是中国第一汽车集团有限公司主办的国内外公开发行的汽车前瞻与应用技术类月刊,为我国高质量科技期刊分级目录入选期刊、中国科学引文数据库(CSCD)来源期刊、中文核心期刊、中国科技核心期刊、RCCSE中国核心学术期刊(A)、俄罗斯《文摘杂志》(AJ)收录期刊。

《汽车技术》杂志以报道汽车整车及其零部件设计、研究、试验等方面的前瞻与应用技术为主,并兼有理论研究成果,是中国汽车行业核心学术和知识传播与共享的平台。

《汽车技术》将在国家提出的“创新、协调、绿色、开放、共享”发展理念的指引下,把握《节能与新能源汽车技术路线图2.0》和“低碳化、信息化、智能化”的汽车技术主流发展趋势,努力在传统内燃机汽车高效动力系统、轻量化、低阻力领域,新能源汽车和互联智能汽车技术领域,大力吸收优质稿源,为广大科研和工程技术人员服务,为我国汽车工程技术创新能力提升贡献力量。

《汽车技术》欢迎高等院校师生、研发工程技术人员、技术管理人员及相关人员不吝赐稿,反映国家重点扶持项目、自然科学基金项目和其他重点项目等研究成果的稿件将被优先选择刊登。

投稿要求:

- 1.文章字数最好控制在6 000~8 000字范围之内;
- 2.请按科技论文要求撰写文章摘要,摘要中文字数控制在180字左右;
- 3.文章必须附有公开发表的、体现本领域最新研究成果的参考文献,且在文中应标注文献引用处;
- 4.文章主要作者应提供其简介,包括出生年、性别、职称、学历、研究方向及技术成果等;
- 5.来稿的保密审查工作由作者单位负责,确保署名无争议,文责自负;
- 6.请勿一稿多投;
- 7.本刊使用网站投稿,请先登陆网站注册成功后投稿,详细投稿要求见本刊网站中“下载中心”栏的“作者指南”,

网址:<http://qcjs.cbpt.cnki.net>。

《汽车技术》杂志编辑部