

CNN-GRU 和 SSA-VMD 在扬声器 异常声分类中的应用*

周静雷 贺家琛 崔琳

(西安工程大学电子信息学院 西安 710048)

摘要: 为了提高扬声器异常声分类的平均准确率,提出用卷积神经网络加门控循环单元(convolutional neural network plus gated recurrent unit, CNN-GRU)和麻雀搜索算法优化变分模态分解(sparrow search algorithm optimization variational modal decomposition, SSA-VMD)模型进行扬声器异常声分类。在特征提取方面,用 SSA-VMD 模型,确定 VMD 中二次惩罚因子(α)和模态分解数(k)的最优取值问题,借此提高特征提取精度,减少提取时间,最后再利用 VMD 提取扬声器响应信号的特征;在分类网络方面,用 CNN-GRU 网络来进行扬声器异常声分类,以 CNN 为基础特征提取网络,再用 GRU 网络进行更深层特征提取,达到提高扬声器平均分类准确率的目标。试验结果表明,经 SSA-VMD 模型优化参数后,VMD 可以更有效提取特征,且分解时间缩短 59.8%;CNN-GRU 模型具有更高和更稳定的识别率,其平均分类准确率为 99.2%。

关键词: 扬声器异常声;变分模态分解;卷积神经网络;门控循环单元;麻雀搜索算法

中图分类号: TN911.72;TP181

文献标识码: A

国家标准学科分类代码: 510.40

Application of CNN-GRU and SSA-VMD in loudspeaker abnormal sound classification

Zhou Jinglei He Jiachen Cui Lin

(College of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: In order to improve the average accuracy of loudspeaker abnormal sound classification, a convolutional neural network plus gated current unit (CNN-GRU) and sparrow search algorithm optimization variational modal decomposition (SSA-VMD) model was proposed to classify loudspeaker abnormal sound. In the aspect of feature extraction, the SSA-VMD model was used to determine the optimal value of the second penalty factor (α) and modal decomposition number (k) in VMD, so as to improve the accuracy of feature extraction and reduce the extraction time. Finally, the VMD was used to extract the characteristics of the loudspeaker response signal. In terms of classification network, the CNN-GRU network was used to classify the abnormal sound of loudspeakers, the CNN-based feature extraction network was used, and the GRU network was used for deeper feature extraction to achieve the goal of improving the average classification accuracy of loudspeakers. The experimental results show that after optimizing the parameters of SSA-VMD model, VMD can extract features more effectively, and the decomposition time was reduced by 59.8%. The CNN-GRU model has a higher and more stable recognition rate, with an average classification accuracy of 99.2%.

Keywords: loudspeaker abnormal sound; variational mode decomposition; convolutional neural networks; gated recurrent unit; sparrow search algorithm

0 引言

扬声器无论是在研发阶段,还是生产阶段,其异常声检测都是必须的。而且分类的时效性,准确率,对扬声器

的生产效率而言,具有很大的影响^[1]。扬声器故障类型有良品、异物、缺胶、碰圈、脱盆架、音小、纸盆声等,正确区分故障类型,可有效保障产品的质量。

在大信号驱动下,扬声器是非线性器件^[2-3],本文主要研究非线性非平稳信号。文献[4]利用经验模态分解

(empirical mode decomposition, EMD)对含有白噪声信号的信号进行分解,在分解过程中对模态分量进行去噪处理,保留最终模态分量。文献[5]提出一种基于集合经验模态分解(ensemble empirical mode decomposition, EEMD)与样本熵的扬声器异常声特征提取方法并利用极限梯度提升(XGBoost)算法进行分类。基于传统时频分析方法在非线性和非平稳信号存在的局限性^[6], Dragomiretskiy 等^[7]于 2014 年提出了 VMD。文献[8]为了解决传统分解方法存在的模态混叠问题,使用了 VMD,然后为了提高分类准确率,从分解后的各模态中提取了能量熵特征,最后用遗传算法优化的支持向量机模型对扬声器异常声进行分类。文献[9]将振动信号通过小波包进行分解^[10-11],通过自适应图卷积核图中节点与边进行特征提取,增强模型在强噪声条件下的泛化性。最后利用全连接层进行特征抽取,进而实现故障诊断。

由于 VMD 中参数 α 和 k 对分解结果影响较大,但其最优值没有确切规定,在不同的应用场景下,其数值大小的确定受个人主观影响较大,没有一个客观评价标准,所以本文用包络谱特征因子来衡量 VMD 分解效果的优劣,用 SSA-VMD^[12]模型对参数 α 和 k 进行寻优,确定一对最适合扬声器异常声分类的数值,达到提高特征提取精度,减少提取时间的目的。异常声分类传统方法有支持向量机^[13-14](support vector machine, SVM)、XGBoost^[15]等,但是此类方法对扬声器异常声分类而言,准确率相对较低,所以本文引入 CNN-GRU 模型。虽然 CNN 模型在异常声分类试验中,可以得到较高的分类精度,但单独的 CNN 模型分类效果不稳定,所以本文在 CNN 的基础上引入了 GRU 网络,GRU 网络可以加强特征前后的时序联系,提高网络深度,形成的 CNN-GRU^[16]神经网络模型对扬声器异常声分类准确率有较大提高。

1 SSA-VMD

1.1 SSA 基本原理

麻雀搜索算法是依据麻雀种群捕食特性而提出的。种群成员分为发现者,加入者和侦察者,根据文献[12]可知其位置参数更新公式如下。

其中发现者位置更新如下:

$$x_{ij}^{t+1} = \begin{cases} x_{ij}^t \cdot \exp\left(\frac{-i}{\alpha \cdot \text{MaxCycle}}\right), R_2 < ST \\ X_{ij}^t + QL, R_2 \geq ST \end{cases} \quad (1)$$

式中: MaxCycle 代表最大迭代次数; α 和 Q 为随机数,前者取值为 $(0, 1]$; L 表示 $1 \times d$ 的矩阵; $R_2 \in [0, 1]$; $ST \in [0.5, 1]$ 。

加入者位置更新如下:

$$x_{ij}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{x_{\omega_j}^t - x_{ij}^t}{t^2}\right), i > NP/2 \\ x_{ij}^{t+1} + |x_{ij}^t - x_{pj}^{t+1}| \cdot A^+ \cdot L \end{cases} \quad (2)$$

式中: x_{pj}^{t+1} 为迭代到 $t+1$ 时发现者所处的最好位置; $x_{\omega_j}^t$ 为迭代到第 t 次的全局最差位置; NP 代表了整个种群规模的大小; A 表示一个 $1 \times d$ 的矩阵,且 $A^+ = A^T(AA^T)^{-1}$ 。

侦察者位置更新如下:

$$x_{ij}^{t+1} = \begin{cases} x_{ij}^t + \beta |x_{ij}^t - x_{bj}^t|, f_i \neq f_g \\ x_{ij}^t + K \frac{|x_{ij}^t - x_{\omega_j}^t|}{(f_i - f_{\omega}) + \varepsilon}, f_i = f_g \end{cases} \quad (3)$$

式中: β 为步长控制参数; k 是随机数, $[-1, 1]$ 之间; f_i 为适应度, f_g 和 f_{ω} 分别为最优和最差值。

1.2 VMD 基本原理

VMD 采用非递归方式,将复杂多分量信号分解为有 K 个有限带宽的调幅调频信号。具体流程如下:

- 1) 初始化参数(如迭代次数 n , 模态分量 u_k , 中心频率 ω_k)。
- 2) 循环 $n = n + 1$, 更新模态分量和中心频率。
- 3) 更新 λ (拉格朗日乘子), 判别精度 ε 是否满足预设条件,若满足停止迭代,输出分解结果。

1.3 SSA-VMD 基本原理

由于 VMD 中参数 α 和 k 对分解结果影响较大,但又没有确定的值,其最优值大小需要结合特定的场景来确定。所以文献[17]中提出用包络谱特征因子来衡量 VMD 分解效果的优劣。本文也借用这种方法来衡量扬声器异常声经 VMD 的好坏。SSA-VMD 模型的流程图如图 1 所示。

由图 1 可知,SSA-VMD 模型首先取正常声频和每种异常声频各 10 条,作为数据样本。然后对 SSA 进行初始化,产生种群,随机生成 α 和 k 。将生成的参数代入 VMD 中,对事先选好的数据样本求取包络谱特征因子平均值,作为衡量 VMD 分解好坏的评判标准,最后根据预设条件进行参数寻优。

2 CNN-GRU

CNN 是一种成熟的深度学习框架,在许多领域都有广泛应用^[18]。其特点是可以提取数据中隐藏的特征,并通过卷积、池化等操作进一步生成更高层的特征。但是由于其层与层之间不具备记忆功能,所以导致其缺乏前后层之间的时序联系。

GRU^[19]是由长短期记忆网络(long short-term memory, LSTM)演变而来,与 LSTM^[20]的结构相比,GRU 构建了一种结构更加简单的神经网络,并且有效的缩短




图1 SSA-VMD 流程

Fig. 1 The flow chart of SSA-VMD

了训练时间。GRU 神经网络是一种时间递归神经网络, 能够将历史数据重新输入到当前网络中, 加强了数据间的联系。

CNN-GRU 模型主要由 3 对连续的卷积层加池化层, 2 个 GRU 层和 1 个全连接层组成, 最后由 SoftMax 函数进行分类。扬声器异常声分类整体流程如图 2 所示。

图 2 中, m 表示当前模型训练次数, N 表示模型设定的总训练次数; 扬声器异常声分类分为预处理, 网络模型训练, 模型测试 3 部分。

3 试验与分析

3.1 试验说明

试验计算使用 Google 公司的 TensorFlow 框架, 计算机配置为 Inter (R) Core (TM) i5-7300CPU @ 2.50 GHz, 8 GB 运行内存。

试验扬声器的型号为 3580-3 型, 其谐振频率为




图2 扬声器异常声分类流程

Fig. 2 Flow chart of loudspeaker abnormal sound classification

180 Hz; 扬声器激励信号为 1 800~20 Hz 的连续对数扫频信号, 时长为 1 s。试验共采集了良品、异物、缺胶、碰圈、脱盆架、音小、纸盆声 7 种状态下的扬声器, 每种扬声器各 14 个。其中异物指扬声器单元中存在铁屑等松散颗粒, 缺胶指防尘帽或压边缺胶, 碰圈指音圈变形或支架不平导致与磁体发生碰撞, 脱盆架指盆架安装松动, 音小指支片沾有胶水或者磁钢未充磁, 纸盆声指纸盆破裂变形等。数据采集框图如图 3 所示。




图3 数据采集框图

Fig. 3 Data acquisition block diagram

由图 3 可知, 激励信号由计算机产生, 由声卡进行数模转换, 经功放放大, 送给被测扬声器, 传声器进行音频采集, 处理后送给声卡进行模数转换, 最后由计算机进行储存。

3.2 SSA-VMD 试验对比

本文提出用 SSA 优化 VMD, 主要是为了解决 VMD 中 α 和 k 的最优值选择问题。优化前 α 选择为 2 000, k 选择为 6; 经 SSA 寻优后, α 选择为 17 001, k 选择为 4。合格扬声器优化前后 VMD 频谱图如图 4、5 所示; VMD 中心频率变化图如图 6、7 所示。

图 5 为优化前频谱图, 从中可以看到原始信号分解为 6 个模态分量, 另外从幅值看, 扬声器能量主要集中在




图 4 VMD 优化后频谱图

Fig. 4 Spectrum diagram after VMD optimization

VMF6, VMF5 和 VMF4 中, VMF3, VMF2 和 VMF1 中能量相对较小;图 4 为优化后频谱图,原始信号被分解为 4 个模态分量;另外从幅值看,扬声器能量主要集中在 VMF4, VMF3, VMF2 中, VMF1 中能量相对较小。幅值大小代表了其从原始声频中提取特征的多少,特征数据主要集中在 3 个能量较大的模态中,其余少量特征用一个模态表示即可,这样做分解时间会大幅减少,优化后单个声频分解时间较优化前减少 59.8%;所以,优化后可以更快更有效提取特征。另外从图 6 和 7 的对比中,也可以看出,优化后的 VMD,其各个模态中心频率较优化前更早分离,且没有出现模态混叠现象。综上,优化后的 VMD 性能优于选择默认参数。

为了进一步验证 SSA-VMD 模型优化效果,后续在确定分类网络时设置了优化前和优化后的对照组;另外,对照组的设置也可以验证分类模型的鲁棒性。

3.3 分类试验对比

1) CNN 分类试验

通过试验,发现在卷积神经网络中,在一定层数范围内,累加卷积层加池化层这一结构,可以有效提高分类准确率。下面分别设置了不同累加层数,用来发现几层结构分类效果最优,有两层,三层,四层,分别命名为模型 1,模型 2 和模型 3,模型 1 如图 8 所示。模型 2 和模型 3 分别在模型 1 的基础上加一对和两对卷积层加池化层结构。

经过多次试验,模型的学习率和训练次数设置为 0.001 和 50,批大小设置为 4 较为合适;表中分类准确率是进行同等条件下 5 次分类试验结果的平均值;后续所有模型参数均设置成这样。3 种模型的扬声器异常声测试集平均计算结果如表 1 所示,训练集的平均损失函数




图 5 VMD 优化前频谱图

Fig. 5 Spectrum diagram before VMD optimization




图 6 VMD 优化后中心频率变化图

Fig. 6 VMD center frequency change diagram after optimization

值对比如图 9 所示。

表 1 CNN 的平均计算结果			
Table 1 Average calculation results of CNN			
模型	准确率/%	损失函数值	时间/s
模型 1 优化前	86.6	0.225 8	1.076
模型 1 优化后	89.5	0.195 2	1.055
模型 2 优化前	96.7	0.061 5	1.103
模型 2 优化后	97.8	0.043 9	1.094
模型 3 优化前	94.3	0.146 3	1.147
模型 3 优化后	93.8	0.191 1	1.142

从表 1 中可以看到模型 2 分类效果最优,使用优化




图7 VMD 优化前中心频率变化图

Fig. 7 VMD center frequency change diagram before optimization




图8 模型1

Fig. 8 Model 1

后的数据,平均分类准确率达到 97.8%;同样由图 9 可知,该模型损失函数值收敛最快,且为最低,所以为最优模型。累加层数太少或太多都会降低分类准确率。另外,表 1 中优化后的分类时间会更少,进一步验证了 SSA-VMD 模型优化效果的优良。




图9 CNN 的平均损失函数值

Fig. 9 Average loss function value of CNN

CNN 网络已经可以将异常声分类准确率提高到一个较高的水平,但是其分类准确率波动较大。模型 2 为最优模型,其 5 次分类准确率分别为 98.7%,99.4%,98.2%,97.5%,95.1%;可以看到,最高和最低分类准确率相差 4.3%,波动较大。

2) CNN-GRU 分类试验

为了改善 CNN 分类结果波动大的问题,引入了 GRU

网络来减少波动,同时提高平均分类准确率;GRU 网络是通过对 CNN 所提取特征做进一步挖掘,发现更深层次的特征;且 GRU 网络加强了数据间的时序联系,提高了模型的识别率。试验中,在 CNN 最优模型基础上分别加入了一层,两层和三层 GRU 层,形成 3 种新的模型,不同模型测试集的平均计算结果如表 2 所示,训练集的平均损失函数值对比如图 10 所示。

表 2 CNN-GRU 的平均计算结果

Table 2 Average calculation results of CNN-GRU

模型	准确率/%	损失函数值	时间/s
单层优化前	92.6	0.191 1	1.161
单层优化后	94.3	0.121 7	1.152
双层优化前	98.8	0.016 5	1.256
双层优化后	99.4	0.010 2	1.210
三层优化前	98.3	0.026 6	1.337
三层优化后	98.7	0.023 8	1.313




图10 CNN-GRU 的平均损失函数值

Fig. 10 Average loss function value of CNN-GRU

从表 2 中可以看到,在 CNN 的基础上加入两层 GRU 层,为最优模型。使用优化后的数据,平均分类精度为 99.4%。其各次分类精度分别为 99.7%,99.2%,99.4%,99.2%和 99.5%,最高和最差分类准确率相差 0.5%,相较于 CNN,无论是在平均分类准确率,还是在模型分类准确率的波动方面,CNN-GRU 网络都会优于 CNN;另外,优化后的分类时间会更少;模型平均分类准确率较优化前基本上都有一定提高,进一步验证了 SSA-VMD 模型优化效果的优良。同时,最优的 CNN-GRU 模型优化前后,分类准确率只相差了 0.4%,且测试集分类平均准确率都在 98.8%及以上;另外,从图 10 中可以看到优化前后的模型损失函数值都很小,说明模型实际的输出与预测值之间差异很小,这些都表明了最优 CNN-GRU 模型具有良好的鲁棒性。最优 CNN-GRU 模型具体参数如表 3 所示。

由表 3 可知,模型输入尺寸为 (72,1),经 CNN 提取特征后,输出维度为 (8,128),后又经 GRU 网络进行更深层次特征提取,最后再通过 SoftMax 函数实现扬声器异常声分类。

表 3 CNN-GRU 模型参数设置

Table 3 CNN-GRU model parameter setting

网络层	参数设置	输入尺寸	输出尺寸
卷积 1 层	核大小 70,核数量 16,步长 4,激活函数 ReLU,填充方式 same	(72,1)	(70,16)
池化 1 层	池化核大小 2,步长 4,填充方式 same	(70,16)	(35,16)
卷积 2 层	核大小 35,核数量 64,步长 4,激活函数 ReLU,填充方式 same	(35,16)	(35,64)
池化 2 层	池化核大小 2,步长 4,填充方式 same	(35,64)	(17,64)
卷积 3 层	核大小 17,核数量 128,步长 4,激活函数 ReLU,填充方式 same	(17,64)	(17,128)
池化 3 层	池化核大小 2,步长 4,填充方式 same	(17,128)	(8,128)
GRU1 层	神经元数 100,激活函数 tanh	(8,128)	(8,100)
GRU2 层	神经元数 50,激活函数 tanh	(8,100)	(50)
全连接层	激活函数 SoftMax	(50)	(7)

3)分类试验总结

通过试验,发现了 CNN-GRU 模型具有良好的鲁棒性,同时为了说明本文方法的优势,进行了对比实验。对 7 种扬声器单元进行小波包分解 (wavelet packet decomposition, WPD) 和 VMD;分解之后对每个子带提取特征;最后使用 LeNet5, VGG 模型与其对比,这两种神经网络模型都有优秀的网络结构,在许多领域都有广泛应用,通过与这两种模型对比,可以有效证明 CNN-GRU 模型的价值。3 种模型平均分类准确率如表 4 所示。

表 4 不同模型平均计算结果

信号分解方法	分类模型	准确率/%	损失函数值
VMD	LeNet5	78.5	0.566 3
	VGG	95.9	0.256 5
	CNN-GRU	99.4	0.010 2
WPD	LeNet5	73.5	0.839 6
	VGG	90.9	0.307 2
	CNN-GRU	96.1	0.153 7

通过表 4 可知,在 3 个分类器的平均分类准确率对比中,可以发现,经 VMD 后的数据分类效果要好于 WPD,说明了 VMD 可以更有效提取特征。在分类器方面,本文所提出的 CNN-GRU 模型分类效果要优于 VGG 和 LeNet5,且在两种特征提取模型中分类效果都是最好的,说明了 CNN-GRU 模型具有良好鲁棒性。

SSA 和灰狼优化 (grey wolf optimization, GWO) 算法优化 VMD,在优化时间, VMD 耗时和准确率 3 方面进行了对比,分类器为 CNN-GRU。具体数据如表 5 所示。可以发现 SSA 优化 VMD 后,在单个音频分解时间和分类准确率方面都要优于 GWO,而且 GWO 优化更消耗时间;综上,本文所提出的方法,在扬声器异常声分类中有更好的效果。

表 5 特征选择方法对比

Table 5 Comparison of feature selection methods			
优化算法	优化 VMD	单个音频	分类准
	耗时/s	VMD 耗时/s	确率/%
SSA-VMD	10 019	19.7	99.4
GWO-VMD	25 198	23.1	95.7
不优化	0	31.5	98.8

3.4 模型评价

为了进一步验证 CNN-GRU 模型的性能,本文采用 K 折叠交叉验证方法。这种方法将试验数据划分为 K 部分,其中 K-1 部分为训练集,剩下的为测试集,通过不断改变训练集和测试集中的数据,可以充分验证模型的性能。

本文选用了 LeNet5, VGG 和 CNN-GRU 这 3 种模型进行验证,试验数据为经过优化后的数据,选择 K 为 10,具体计算结果如表 6 所示;交叉验证的计算过程如图 11 所示。

表 6 不同模型的评价结果

Table 6 Evaluation results of different models		
模型	准确率/%	模型误差/%
LeNet5	72.5	10.5
VGG	82.9	6.4
CNN-GRU	99.2	0.6

由表 6 可知, CNN-GRU 模型表现好于 LeNet5 和 VGG,其平均分类准确率达到 99.2%,模型误差仅 0.6%;图 11 中也可以看出, CNN-GRU 模型在波动和准确率方面都要优于其他模型。试验结果表明,本文提出的 CNN-GRU 模型具有模型训练充分,计算结果优良,误差值较小的特点,且并未出现过拟合或者欠拟合等现象。

4 结 论

本文提出一种基于 SSA-VMD 和 CNN-GRU 模型的




图 11 K 折叠交叉验证计算过程

Fig. 11 K-fold cross validation calculation process

扬声器异常声分类方法,为了解决 VMD 中二次惩罚因子和模态分解数的最优值选择的问题,引入 SSA-VMD 模型,以包络谱特征因子作为评判 VMD 提取特征好坏的标准,以 SSA 作为寻优算法确定 VMD 中的最优参数;此外,针对 CNN 模型在扬声器异常声中分类效果不稳定的情况,引入 CNN-GRU 模型,以 CNN 作为基础特征提取网络,用 GRU 网络加深总的网络层数,提取更深层特征,进而提高扬声器异常声平均分类准确率。近年来模态分解方法结合神经网络模型在异常声分类方面展现出了极大优势,但在分类的实时性方面仍存在不足,主要是因为现有数据下,模态分解算法提取异常声特征时间较长,在接下来的工作中,会引入基频陷波后的扬声器异常声数据,消除异常声响应信号中的激励信号分量,并对模态分解算法进行改进,提高其提取特征的效率,从而提高扬声器异常声分类的实时性。

参考文献

- [1] STEFAN I, KLIPPEL W. Fast and sensitive end-of-line testing[J]. Audio Engineering Society Convention 144, Audio Engineering Society, 2018:9927-9937.
- [2] BAI M, HUANG C. Expert diagnostic system for moving-coil loudspeakers using nonlinear modeling[J]. Journal of the Acoustical Society of America, 2009, 125(2): 819-830.
- [3] 黄杰,沈勇,王坤,等. 封闭式扬声器系统空气劲度的非线性研究[J]. 应用声学, 2015, 34(6): 471-476.
HUANG J, SHEN Y, WANG K, et al. Nonlinear study on air stiffness of enclosed loudspeaker system [J]. Applied Acoustics, 2015, 34(6): 471-476.
- [4] 王立宪,马宏忠,戴锋. 基于改进 SVD-EMD 的绝缘子泄漏电流去噪方法[J]. 电子测量与仪器学报, 2022, 36(1): 166-173.
WANG L X, MA H ZH, DAI F. Insulator leakage current denoising method based on improved SVD-EMD [J]. Journal of Electronic Measurement and Instrumentation,

2022, 36(1): 166-173.

- [5] 周静雷,房乔楚,颜婷. EEMD 样本熵的扬声器异常音分类方法[J]. 电子测量与仪器学报, 2019, 31(4): 195-201.
ZHOU J L, FANG Q CH, YAN T. Method of classification for loudspeaker abnormal sound based on EEMD and sample entropy [J]. Journal of Electronic Measurement and Instrumentation, 2019, 31(4): 195-201.
- [6] MOHANTY S, GUPTA K K, RAJU K S. Hurst based vibroacoustic feature extraction of bearing using EMD and VMD [J]. Measurement, 2017, 117: 200-220.
- [7] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [8] 周静雷,颜婷. 应用变分模态分解及能量熵的扬声器异常声分类[J]. 声学学报, 2021, 46(2): 263-270.
ZHOU J L, YAN T. Loudspeaker abnormal sound classification using variational mode decomposition and energy entropy [J]. Acta Acustica, 2021, 46(2): 263-270.
- [9] 余晓霞,汤宝平,魏静,等. 强背景噪声条件下自适应图卷积神经网络的航空发动机附件机匣故障诊断方法[J]. 仪器仪表学报, 2021, 41(8): 78-86.
YU X X, TANG B P, WEI J, et al. Fault diagnosis method of aero engine accessory casing based on adaptive graph convolutional neural network under strong background noise [J]. Chinese Journal of Scientific Instrument, 2021, 41(8): 78-86.
- [10] 胡业林,代斌,宋晓. 基于小波包和 AFSA-SVM 的电机故障诊断[J]. 电子测量技术, 2021, 44(2): 48-55.
HU Y L, DAI B, SONG X. Electric motor fault diagnosis based on wavelet packet and AFSA-SVM [J]. Electronic Measurement Technology, 2021, 44(2): 48-55.
- [11] 靳小强,王建斌,杜云鹏. 改进小波包阈值法在导波信号处理中的应用[J]. 国外电子测量技术, 2012, 31(6): 55-58.
JIN X Q, WANG J B, DU Y P. Application of improved wavelet packet threshold method in guided wave signal processing [J]. Foreign Electronic Measurement Technique, 2012, 31(6): 55-58.
- [12] XUE J K, SHEN B. A novel swarm intelligence optimization approach: Sparrow search algorithm [J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [13] 张明阳,查诚,塔什甫拉提·尼扎木丁,等. 结合数据场情感空间和混合蛙跳算法的连续语音情感变化趋势检测[J]. 声学学报, 2019, 44(1): 12-19.

- ZHANG M Y, ZHA CH, TASHPOLATI N, et al. Continuous speech emotion trend detection based on data field emotion space and shuffled frog-leaping algorithm [J]. Acta Acustica, 2019, 44(1): 12-19.
- [14] ZHANG L W, ZHOU Z D, XUE Y F, et al. Classification of imagined speech EEG signals with DWT and SVM[J]. Instrumentation, 2022, 9(2): 56-63.
- [15] CHEN T, GUESTRIN C. Xgboost: A scalable tree boosting system [C]. Proceedings of the 22nd Acm Sigkdd International Conference on Knowledge Discovery and Data Mining. ACM, 2016; 785-794.
- [16] XIANG W, LI F, WANG J, et al. Quantum weighted gated recurrent unit neural network and its application in performance degradation trend prediction of rotating machinery[J]. Neurocomputing, 2018, 313: 85-95.
- [17] 唐贵基, 王晓龙. 变分模态分解方法及其在滚动轴承早期故障诊断中的应用[J]. 振动工程学报, 2016, 29(4): 638-648.
- TANG G J, WANG X L. Variational mode decomposition method and its application in early fault diagnosis of rolling bearing [J]. Journal of Vibration Engineering, 2016, 29(4): 638-648.
- [18] BAHMEI B, BIRMINGHAM E, ARZANPOUR S. CNN-RNN and data augmentation using deep convolutional generative adversarial network for environmental sound classification[J]. IEEE Signal Processing Letters, 2022, 29: 682-686.
- [19] HUANG G, LI X, ZHANG B, et al. PM2.5 concentration forecasting at surface monitoring sites using GRU neural network based on empirical mode decomposition[J]. Science of the Total Environment, 2021, 768(3): 144516.
- [20] AHMADZADEH B, KIM H, JEONG O, et al. A deep bidirectional LSTM-GRU network model for automated ciphertext classification[J]. IEEE Access, 2022, 10: 3228-3237.

作者简介



E-mail: 2431255532@qq.com

Zhou Jinglei (Corresponding author) received his B. Sc. and Ph. D. degrees both from Nanjing University in 2000 and 2005, respectively. Now he is an associate professor in Xi'an Polytechnic University. His main research interests include virtual instrument development for electroacoustic measurement, embedded system development for acoustic signal processing, acoustic signal processing.



he is a M. Sc. candidate in Xi'an Polytechnic University. His main research interest includes loudspeaker abnormal sound detection.



Cui Lin received her B. Sc. from Inner Mongolia University of Science and Technology in 2006, M. Sc. and Ph. D. degrees both from Northwestern Polytechnic University in 2009 and 2013, respectively. Now she is a lecturer at Xi'an Polytechnic University. Her main research interest includes array signal processing.

周静雷(通信作者), 分别在 2000 年和 2005 年于南京大学获得学士学位和博士学位, 现为西安工程大学副教授, 主要研究方向为电声测量虚拟仪器开发, 嵌入式系统在声信号处理中的应用、声频信号处理。

贺家琛, 2020 年于洛阳师范学院获得学士学位, 现为西安工程大学硕士研究生, 主要研究方向为扬声器的异常声检测。

E-mail: hjc232425happy@163.com

He Jiachen received his B. Sc. degree from Luoyang Normal University in 2020. Now he is a M. Sc. candidate in Xi'an Polytechnic University. His main research interest includes loudspeaker abnormal sound detection.

E-mail: 957994787@qq.com

崔琳, 分别在 2006 年于内蒙古科技大学获得学士学位, 2009 年和 2013 年于西北工业大学获得硕士学位和博士学位, 现为西安工程大学讲师, 主要研究方向为阵列信号处理。