

DOI:10.19651/j.cnki.emt.2108699

VMD多尺度熵和GWO-SVM在扬声器异常声分类中的应用*

周静雷 丁芳 崔琳
(西安工程大学电子信息学院 西安 710600)

摘要:针对扬声器异常声分类中异常声特征提取以及分类识别两个关键环节,提出一种基于变分模态分解(VMD)多尺度熵(MSE)与灰狼算法优化支持向量机(GWO-SVM)结合的扬声器异常声分类方法。首先,对扬声器声响应信号进行VMD分解得到一系列本征模态函数(IMF),计算各阶IMF与原始信号的相关系数,然后选择相关系数高的IMF提取该IMF的MSE作为特征向量,最后利用灰狼算法优化支持向量机模型识别故障类型。实验结果表明,在5种状态下扬声器单元分类的识别中,较经验模态分解(EMD)多尺度熵、VMD多尺度散布熵(MDE)、EMD多尺度散布熵的特征提取方法,VMD多尺度熵呈现出更高的识别准确率,其识别准确率为99.3%。能更好地表征异常声特征。

关键词:异常声分类;变分模态分解;多尺度熵;灰狼算法

中图分类号:TN912 文献标识码:A 国家标准学科分类代码:140.2

Application of VMD-MSE and support vector machine in the loudspeaker rub & buzz automatic classification

Zhou Jinglei Ding Fang Cui Lin

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710600, China)

Abstract: Aiming at the two key links of loudspeaker fault diagnosis and fault recognition in the process of loudspeaker rub & buzz automatic classification, an automatic classification method of loudspeaker rub & buzz based on variational mode decomposition (VMD) multiscale entropy (MSE) and grey wolf optimizer-support vector machines is proposed. First, the radiated acoustical signals of loudspeaker units were decomposed by VMD, and calculate the correlation coefficient of each intrinsic mode function (IMF) with the original signal. Then, select the IMF component with high correlation coefficient to extract the multi-scale entropy as the feature vector. Finally, the loudspeaker rub & buzz was judged by GWO-SVM. The experimental results show that, compared with the empirical mode decomposition (EMD) multi-scale entropy, VMD multiscale dispersion entropy (MDE), and EMD multiscale dispersion entropy, VMD multi-scale entropy has a higher recognition rate, The recognition accuracy rate is 99.3%. VMD multi-scale entropy can more accurately characterize the loudspeaker rub & buzz characteristics of the loudspeaker unit.

Keywords: rub & buzz automatic classification; variational mode decomposition; multiscale entropy; grey wolf optimizer

0 引言

扬声器单元(简称扬声器)是应用广泛的电声转换器件,对扬声器进行异常声检测是扬声器生产阶段至关重要的环节,提高扬声器故障诊断的自动性、快速性及诊断结果的高准确性有着重要的理论和实用价值。

扬声器在大信号驱动下,其声响应信号为非线性、非平稳信号^[1]。并且扬声器种类繁多,结构复杂。因此扬声器

声响应信号复杂,故障特征信号非常微弱且不稳定,难以被识别,这也是扬声器异常声特征提取中的难点。近年来,对于异常声分类的研究,主要集中在对声响应信号进行时频域分析的特征提取上。文献[2-3]针对不同激励信号,基于音频质量感知评估(perceptual evaluation of audio quality, PEAQ)对碰圈、胶合不牢故障扬声器进行分类识别。宋建华等^[4]使用改进尺度不变特征转换算法对扬声器单元声响应信号的傅里叶变换时频图进行特征提取,设定阈值构建

收稿日期:2021-12-27

* 基金项目:国家自然科学基金青年项目(61901347)、陕西省教育厅科技计划项目(18JK0342)资助

检测模型并进行故障分类。以上方法多需要人为设置阈值,难以实现分类的自动化^[3]。

对于非线性、非平稳信号的自适应时频分析,文献[6]提出了经验模态分解(empirical mode decomposition, EMD),EMD将复杂的非线性、非平稳信号分解为若干个本征模态函数(intrinsic mode function, IMF)和余项^[6]。谷玉海等^[7]提出一种基于EMD与卷积神经网络的方法,对轴承振动信号进行EMD,选取相关系数最大的IMF进行频谱分析,提取频谱图转化为特征二值化图像输入CNN进行训练与分类识别,对不同状态的轴承有较好的识别率。EMD在轴承、齿轮等旋转机械的故障特征提取领域有广泛的应用,但容易出现模态混叠和虚假分量现象^[8-9]。在EMD的基础上,文献[10-11]提出变分模态分解(variational mode decomposition, VMD),能够很好的解决EMD中存在的模态混叠问题。李余兴等^[12]对4类舰船信号VMD,提取IMF的中心频率和排列熵作为融合特征向量,输入支持向量机模型进行分类识别。

近年来,许多应用在机械动力学系统的衡量时间序列复杂性的方法相继被提出并应用到非线性、非平稳信号的特征提取过程中^[13]。熵作为敏感特征量也被广泛应用到故障诊断领域中,故障诊断中常见的信息熵有近似熵(approximate entropy, AE)、排列熵(permutation entropy, PE)、模糊熵(fuzzy entropy, FE)等。单一尺度的信息熵很难全面反映故障信息,Costa等^[14]提出一种对时间序列进行多尺度分解的算法,能够从多个维度描述信号的复杂度。因此对信号进行多尺度熵分析成为故障诊断中特征提取的一个方向^[15]。黄大荣等^[16]针对石化装备轴承故障诊断精度不高的问题,提出了一种基于改进VMD和多尺度熵的特征提取方法,可以很好地提取石化装备轴承故障特征且故障识别精度较高。

多尺度熵在非线性、非平稳信号的特征提取中已经有了广泛的应用,但很少有学者将VMD多尺度熵引用到扬声器的异常声分类中。为了解决扬声器异常声特征提取困难的问题,提高故障识别的准确率。本文基于VMD多尺度熵(multi-scale entropy, MSE)和灰狼算法优化支持向量机(grey wolf optimizer-support vector machines, GWOSVM)提出一种扬声器异常声分类新方法。对不同状态下的扬声器单元声响应信号进行VMD得到若干IMF,计算IMF与原始信号的相关系数,选取包含主要特征信息的IMF分量计算其MSE作为特征向量。最后将提取的特征向量输入到GWO-SVM分类模型中,进行故障诊断,并与EMD-MSE、VMD-MDE、EMD-MDE进行了对比,以验证所提取的VMD-MSE特征的有效性。

1 理论分析

1.1 变分模态分解

VMD是一种采用非递归方式将复杂信号分解为 K 个

有限带宽信号的分析算法。VMD实际上是式(1)的求解:

$$\begin{cases} \max_{\{u_k\}, \{\omega_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi\tau} \right) \cdot u_k(t) \right] e^{j\omega_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k(t) = f(t) \end{cases} \quad (1)$$

式中: K 为IMF分量个数, $\|\cdot\|_2^2$ 代表平方和L2范数, $\{u_k\} := \{u_1, u_2, \dots, u_k\}$ 为模态分量, $\{\omega_k\} := \{\omega_1, \omega_2, \dots, \omega_k\}$ 为瞬时频率, $f(t)$ 为声响应信号。

引入二次惩罚因子 α 和拉格朗日乘子 λ ,得到拓展拉格朗日表达式如式(2)所示。

$$\begin{aligned} \mathcal{L}(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi\tau} \right) \cdot u_k(t) \right] e^{-j\omega_k t} \right\|_2^2 + \\ & \left\| f(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), f(t) - \sum_{k=1}^K u_k(t) \rangle \end{aligned} \quad (2)$$

VMD算法流程如下:

1) 参数初始化。设置 $\{u_k^1\} = 0, \{\omega_k^1\} = 0, \lambda^1 = 0$, 迭代次数 $n=0, \tau=0, \epsilon=10^{-6}$ ^[5]。

2) 循环 $n=n+1$,根据式(3)、(4)更新 $u_k(t)$ 和 $\omega_k(t)$ 。

$$u_k^{n+1}(\omega) = \frac{f(\omega) - \sum_{j \neq k} u_j(\omega) + \frac{\lambda(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (3)$$

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |u_k(\omega)|^2 d\omega}{\int_0^\infty |u_k(\omega)|^2 d\omega} \quad (4)$$

3) 根据式(5)更新 λ , 设置判别精度 $\epsilon > 0$, 直到满足

$$\begin{aligned} \sum_{k=1}^K \left\| u_k^{(n-1)} - u_k^n \right\|_2^2 / \left\| u_k^n \right\|_2^2 < \epsilon, \text{ 停止迭代。} \\ \lambda^{n+1}(\omega) = \lambda^n(\omega) + \tau \left[f(\omega) - \sum_k u_k^{n+1}(\omega) \right] \end{aligned} \quad (5)$$

1.2 多尺度熵

熵是一种度量时间序列复杂度的方法,可以用来描述数据信息的不确定性。样本熵(sample entropy, SampEn)经常用来表征较短时间序列的含噪声情况^[17]。多尺度熵是基于SampEn提出的优化特征算法,对原始时间序列进行粗粒化处理,可以反映不同尺度下时间序列的复杂性程度,相比于样本熵包含了更丰富的信息^[11]。MSE的计算步骤为:

1) 参数初始化。多尺度熵包含3个参数:嵌入维数 m 、相似容限 r 及尺度因子 τ 。其中 m 和 τ 中的分量均为正整数。尺度因子 $\tau = [1, 2, \dots, \tau_{\max}]$ 。

2) 粗粒化(coarse graining)处理。将原始数据 $X = \{X_1, X_2, \dots, X_N\}$ 进行粗粒化处理。

$$y_j(\tau) = \frac{1}{\tau} \sum_{i=j-\tau+1}^j x_i, 1 \leq j \leq \frac{N}{\tau} \quad (6)$$

3) 计算粗粒化向量序列的样本熵。

(1) 设置模式维数 m , 组成 m 维新序列 $Y(i) = [y_i(\tau), y_{i+1}(\tau), \dots, y_{i+m-1}(\tau)]$, 其中 $1 \leq i \leq N - m$ 。

(2) 定义 $Y(i)$ 和 $Y(j)$ 之间的距离:

$$d(i, j) = \max_k |y_{i+k}(\tau) - y_{j+k}(\tau)| \quad (7)$$

其中, $1 \leq j \leq N - m, j \neq i$ 。

(3) 设定相似容限 r , 计算满足约束条件 $d(i, j) < r$ 的 i 值数量, 计算此数与距离总数 $N - m + 1$ 的比值, 记作 $B_i^m(r)$, 其平均值记作 $B^m(r)$ 。

$$B_i^m(r) = \frac{[d(i, j) < r]}{N - m + 1} \quad (8)$$

$$B^m(r) = \frac{1}{N - m} \sum_{i=1}^m B_i^m(r) \quad (9)$$

(4) $m \leftarrow m + 1$, 重复步骤(1)~(3), 得到 $B^{m-1}(r)$ 。

(5) 理论上, 此序列的样本熵为:

$$\text{SampleEn}(m, r) = \lim_{N \rightarrow \infty} \left[-\ln \frac{B^{m+1}(r)}{B^m(r)} \right] \quad (10)$$

当 N 取有限值时:

$$\text{SampleEn}(m, r, N) = -\ln \frac{B^{m+1}(r)}{B^m(r)} \quad (11)$$

计算每个尺度序列的 SampleEn , 即可得到:

$$\text{MSE}(X) = \text{SampleEn}(y(\tau), m, r) \quad (12)$$

2 实验研究

2.1 实验数据采集

实验数据采集过程中使用的扬声器单元为 3580-3 型, 该扬声器单元阻抗为 6Ω , 额定功率为 10 W, 谐振频率为 180 Hz。激励信号为时长为 1 s, 电压为 1 V, 频率为 1 800~20 Hz 的连续对数扫频信号^[5]。实验数据采集平台原理如图 1 所示。




图1 实验测试原理

本次实验样本为合格、碰圈、垃圾声、帽子失风、缺胶 5 种状态的扬声器单元。垃圾声指扬声器单元中存在铁屑、磁碎、毛刺与音圈碰触所发出的声音, 帽子失风指防尘帽故障导致漏气, 碰圈指音圈歪、变形、支片不平导致音圈与其他部件发生碰触, 缺胶指压边、纸盆、支片外径等缺胶, 与部件发生碰触。

2.2 异常声信号的变分模式分解

VMD 分解需要预先设定惩罚因子 α 和模态个数 K , 这两个参数会直接影响到 VMD 的分解效果。惩罚因子 α 越大, 越不易出现模态混叠现象, 但带宽越窄; α 过小则容易出现模态混叠。模态个数 K 过大, 容易造成模态混叠; K 过小, 会遗失原始信号的特征信息。综合考虑模态混叠问题和收敛速度, 选取具有较强自适应性的标准 VMD 中

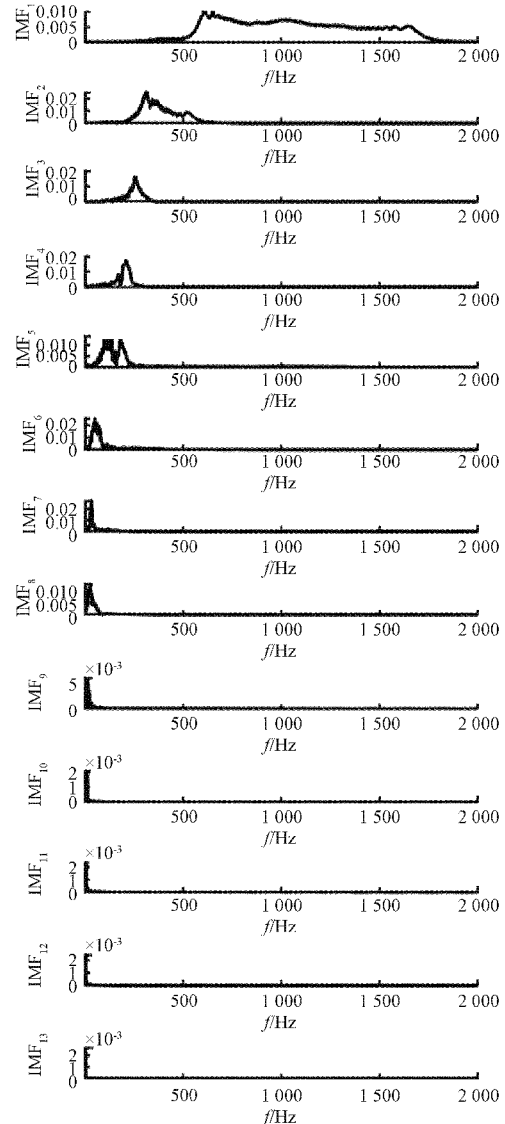
的默认设置, 即 $\alpha = 2\ 000$ 。对于模态个数 K , 根据观察不同 K 值下的 IMF 中心频率进行选择, 选择合格扬声器单元声响应信号进行 VMD 分解, 不同 K 值对应的 IMF 中心频率如表 1 所示。

表1 不同 K 值下 IMF 对应的中心频率

K 值	中心频率/Hz						
4	194	419	928	1 447			
5	63	290	648	1 046	1 499		
6	63	288	623	961	1 248	1 574	
7	61	284	574	813	1 258	1 311	1 593

从表 1 可以看出, 在 $K = 7$ 时, IMF₅ 的中心频率为 1 258 Hz, IMF₆ 的中心频率为 1 311 Hz, 中心频率相近可能会出现模态混叠现象, 由此可见确定 $K = 6$ 较为合适。

选取合格扬声器单元声响应信号分别进行 VMD 和 EMD 分解。分解结果频谱如图 2 所示。



(a) EMD分解频谱图




图 2 合格扬声器单元声响应信号分解结果

由图 2(a)可知,扬声器声响应信号被 EMD 自适应的分解为 12 个 IMF 和余项,分解结果中 IMF₁~IMF₁₂ 波形的中心频率从高到低分布,过度分解导致出现模态混叠现象,其中 IMF₅ 出现了两个中心频率。由图 2(b)可知, VMD 分解将扬声器声响应信号分解 6 个 IMF,各阶 IMF 的中心频率从高到低分布并且没有出现模态混叠的现象。

计算合格扬声器单元声响应信号各阶 IMF 与原始信号的相关系数,如表 2 所示。从表 2 可知,IMF₅ 和 IMF₆ 与原始声响应信号的相关程度较高,在 0.5 以上,故剔除 1~4 阶 IMF 分量,选择 IMF₅ 和 IMF₆ 进行特征提取,从而提高特征提取算法的效率及分类效率。不同状态扬声器单元声响应的 VMD 分解结果 IMF₅ 和 IMF₆ 频谱图如图 3 所示。

表 2 各 IMF 的相关系数

IMF	IMF ₁	IMF ₂	IMF ₃	IMF ₄	IMF ₅	IMF ₆
相关系数	0.227	0.290	0.147	0.320	0.738	0.502

2.3 特征提取

多尺度熵包含 3 个参数:嵌入维数 m 、相似容限 r 及尺度因子 τ 。若 m 取值过小则数据长度增加,不能准确反映信号的突变性,若取值过大会导致时间序列均匀化,无法反映时间序列的信息。相似容限 r 过大会丢失有效特征信息,过大会增强噪声敏感性。综合考虑处理效果与运行效率,取嵌入维数 $m = 2$,相似容限 $r = 0.15$,尺度因子 $\tau_{\max} = 20$ 五种状态扬声器声响应信号进行分析。

5 种故障状态扬声器声响应信号的正则熵均值曲线如图 4 所示。可以看出,不同状态扬声器的熵值变化曲线以 $\tau = 13$ 为分界线, $\tau < 13$ 时,各曲线波动较大且各曲线之间未完全分开; $\tau > 13$ 时,不同扬声器的熵值曲线明

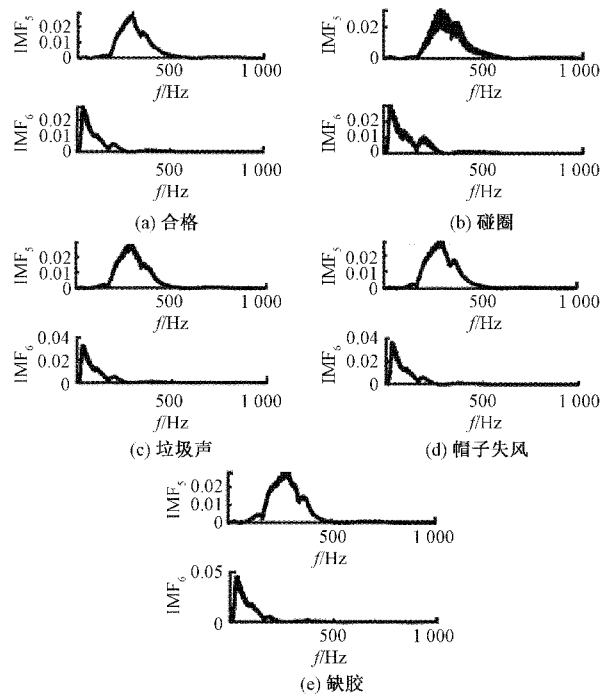


图 3 不同状态扬声器单元声响应信号 VMD 频谱图

显完全分开并趋于平稳。因此,在特征集的构建与分析中选取尺度因子 $\tau = 13$ 的熵值数据进行归一化处理,再输入分类器中进行处理。




图 4 5 种状态声响应信号的正则熵均值

将上述 5 种状态的扬声器声响应信号分别进行 VMD、EMD 分解之后计算优选 IMF 分量的 MSE。5 种状态扬声器部分样本的 EMD-MSE、VMD-MSE 值对比结果如图 5、6 所示。

由熵的定义可知,时间序列越复杂,熵值越大。从图 5~6 可以看出,对比合格、碰圈、垃圾声、帽子失风、缺胶 5 种状态,碰圈状态熵值最大,在实际的使用中,碰圈指音圈歪、变形导致发声过程中与其他部件如 T 铁中柱发生碰触,扬声器声响应信号具有更高的随机性,故熵值较大,与理论结果相吻合。相比于 EMD 分解,VMD 分解获得的熵




图5 5种状态扬声器响应信号的EMD-MSE

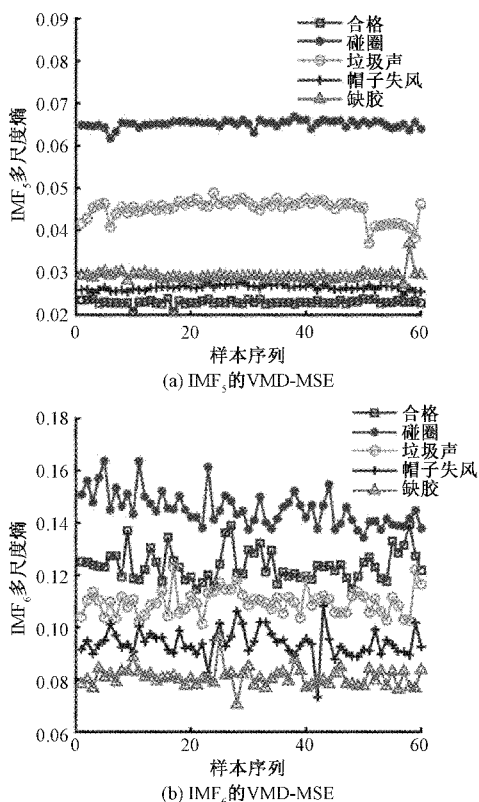


图6 5种状态响应信号的VMD-MSE

值较大,能够更有效地表征不同状态扬声器声响应信号的微弱特征。EMD-MSE的 IMF_5 熵值曲线中,帽子失风和缺胶样本出现了混叠现象; IMF_6 熵值曲线中,碰圈、垃圾声、帽子失风出现了混叠现象,并且分布较为集中。VMD-MSE获得的熵值曲线更为平滑,并且能够有效将5类样本区分开,表明了VMD-MSE算法能够提取出更为稳定的易于区分扬声器异常的熵值特征信息,也体现出VMD-MSE算法的可行性和优越性。

2.4 基于GWO-SVM的扬声器故障类型识别

扬声器异常声分类因为其样本数量较少,容易出现过学习和欠学习的现象。支持向量机算法是基于统计学习理论的模式识别算法,对于小样本数据识别有许多特有优势。所以本文使用支持向量机算法进行分类。

惩罚因子 c 和 g 是支持向量机中对分类性能影响较大的关键参数。Mirjalili等^[18]提出一种元启发式算法—灰狼算法(grey wolf optimizer, GWO)。该算法模仿了灰狼种群特有的等级关系和集体捕猎行为,具有较好的收敛性、结构简单等特点^[19-20]。因此论文采用GWO算法对惩罚因子 c 和 g 进行寻优。

对5种状态扬声器声响应信号分别计算VMD-MSE、EMD-MSE熵值,每种状态分别取30个样本,共150个样本作为训练样本特征数据集,输入到GWO-SVM模型中进行训练。图7为将归一化后的VMD-MSE特征数据集输入到GWO-SVM模型中,惩罚因子 c 、参数 g 的寻优适应度曲线图,结果分别为 $c=184.642$ 、 $g=9.9182$,CV识别率为99.4%。




图7 VMD-MSE的GWO-SVM适应度曲线

每种状态扬声器取30个样本,共150个样本作为测试样本输入训练好的GWO-SVM分类器进行分类识别。VMD-MSE、EMD-MSE分类识别结果如图8所示。

由图8可知,EMD-MSE对于5种不同状态的扬声器单元的识别准确率远低于VMD-MSE的识别准确率,EMD-MSE总体分类识别准确率仅为81.3%,对于垃圾声、帽子失风、缺胶状态扬声器的识别准确率比较低,其中,对于垃圾声状态扬声器单元,30个测试样本中有5个样本识别错误;对于帽子失风状态扬声器单元,30个测试样本




图 8 测试样本识别结果

中有 10 个样本识别错误;对于缺胶状态扬声器单元,30 个样本中有 6 个样本识别错误。而 VMD-MSE 对于各类的识别准确率都较高。测试样本识别准确率为 99.3%,150 个测试样本中仅标签 5,即缺胶状态扬声器单元有一个样本识别错误,远远高于 EMD-MSE 特征下的识别准确率。

为了验证多尺度熵特征的优越性,设置对比实验,以上述同样的方法提取并计算 5 种状态扬声器声响应信号经 VMD、EMD 分解后优选 IMF 分量的多尺度散布熵 (multiscale dispersion entropy, MDE) 作为特征向量,输入 GWO-SVM 中进行训练与测试,识别率如表 3 所示。VMD-MDE 特征下的识别准确率为 70.7%,EMD-MDE 特征下的识别准确率只有 40.7%。

表 3 扬声器异常声分类识别率

特征提取	EMD-MDE	VMD-MDE	EMD-MSE	VMD-MSE
识别率/%	40.7	70.7	81.3	99.3

以上分析可知,经 VMD 提取并计算优选 IMF 的 MSE、MDE 作为特征向量,对于 5 种状态扬声器单元的识别准确率要高于 EMD 的相应熵特征的识别准确率,很大程度上是因为 EMD 存在模态混叠问题,对扬声器异常声的识别准确率造成影响,而 VMD 分解可以很好地解决这一问题;对于 VMD、EMD 提取的 IMF 分量,MSE 特征识别准确率要大于 MDE 特征识别准确率,是由于 MSE 比

MDE 具有更强的抗干扰能力。分析表明优选 IMF 的 VMD-MSE 特征能更好地表征扬声器异常声的特征。

3 结 论

本文将变分模态分解与多尺度熵相结合的方法首次应用到扬声器异常声特征提取中,将特征向量输入灰狼算法优化支持向量机进行分类识别。并通过对比实验分析表明:

1) 基于 VMD 分解的识别准确率高于基于 EMD 分解的识别准确率。与 EMD 相比,VMD 分解的优选 IMF 分量具有明显特征,优选 IMF 分量可以降低特征向量维数,除去冗余信息,有效提高了特征提取的效率和分类精度。

2) 由于熵值的大小只与时间序列的复杂度有关。因此对于不同状态扬声器声响应信号,MSE 具有很好的区分度,分类准确度更高,可以作为敏感特征量用于扬声器异常声分类中。

3) 日前对于 5 种状态的扬声器单元异常声有了较好的分类,但是对于故障程度的判断还没有明确的理论指导。

参考文献

- [1] IRRGANG S, WOLFGANG K. Fast and sensitive end-of-line testing [C]. Audio Engineering Society, 2018: 9927-9937.
- [2] BRUNET P, FALLON B, TEMME S. Practical implementation of perceptual rub & buzz distortion and experimental results[C]. Audio Engineering Society, 2010.
- [3] TEMME S, PASCAL B, PARASTOO Q. Measurement of harmonic distortion audibility using a simplified psychoacoustic model-updated [C]. Audio Engineering Society Conference: 51st International Conference: Loudspeakers and Headphones, Audio Engineering Society, 2013.
- [4] 宋华建,穆瑞林,周子奇.一种基于特征点提取的扬声器异常声检测方法[J/OL].应用声学,2021:1-9, <http://kns.cnki.net/kcms/detail/11.2121.O4.20210812.1650.002.html>.
- [5] 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.
- [6] 范勇,王鹏,张宁超.基于改进 EMD 与 SOM 神经网络的自动机驱动机构故障诊断研究[J].国外电子测量技术,2020,39(8):5-10.
- [7] 谷玉海,朱腾腾,饶文军,等.基于 EMD 二值化图像和 CNN 的滚动轴承故障诊断[J].振动.测试与诊断,2021,41(1):105-113,203.
- [8] WANG J, DU G F, ZHU ZH K, et al. Fault diagnosis of rotating machines based on the EMD manifold [J]. Mechanical Systems and Signal Processing, 2020, 135:106443.

- [9] SINGH D S, ZHAO Q. Pseudo-fault signal assisted EMD for fault detection and isolation in rotating machines [J]. *Mechanical Systems and Signal Processing*, 2016, 81: 202-218.
- [10] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531-544.
- [11] 谢国民,黄睿灵,丁会巧. 基于VMD样本熵和KELM的输电线路故障诊断[J]. *电子测量与仪器学报*, 2019, 33(5):73-79.
- [12] 李余兴,李亚安,陈晓,等. 基于VMD和SVM的舰船辐射噪声特征提取及分类识别[J]. *国防科技大学学报*, 2019, 41(1): 89-94.
- [13] 丁嘉鑫,王振亚,姚立纲,等. 广义复合多尺度加权排列熵与参数优化支持向量机的滚动轴承故障诊断[J]. *中国机械工程*, 2021, 32(2):147-155.
- [14] COSTA M, GOLDBERGER A L, PENG C K. Multiscale entropy analysis of biological signals [J]. *Physical Review. E, Statistical, Nonlinear, and Soft Matter Physics*, 2005, 71(2 Pt 1):021906.
- [15] 张学军,万东胜,孙知信. 基于LMD和模糊熵融合CSP的脑电信号特征提取方法[J]. *仪器仪表学报*, 2020, 41(8):226-234.
- [16] 黄大荣,柯兰艳,林梦婷,等. 一种参数优化VMD多尺度熵的轴承故障诊断新方法[J]. *控制与决策*, 2020, 35(7):1631-1638.
- [17] RICHMAN J S, MOORMAN J R. Physiological time-series analysis using approximate entropy and sample entropy [J]. *American Journal of Physiology. Heart and Circulatory Physiology*, 2000, 278(6):H2039.
- [18] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer [J]. *Advances in Engineering Software*, 2014, 69(3): 46-61.
- [19] 田东雨,何玉珠,宋平. 基于灰狼优化算法的SVM的图像噪声识别[J]. *电子测量技术*, 2019, 42(4):90-94.
- [20] 宁琦,耿读艳,王晨旭,等. 基于多尺度排列熵及PSO-SVM的输电线路故障判别[J]. *电子测量与仪器学报*, 2019, 33(7):173-180.

作者简介

周静雷,副教授,主要研究方向为声频信号处理、虚拟仪器、声学测量、电声学等。
E-mail:jlzhou@xpu.edu.cn