

引用格式: 刘夏扬, 李晶, 赵国新, 等. 基于 IVMD-RPE 的船舶噪声信号去噪及特征提取方法[J]. 声学技术, 2023, 42(3): 297-305. [LIU Xiayang, LI Jing, ZHAO Guoxin, et al. Ship signal denoising and feature extraction based on IVMD-RPE[J]. Technical Acoustics, 2023, 42(3): 297-305.] DOI: 10.16300/j.cnki.1000-3630.2023.03.005

基于 IVMD-RPE 的船舶噪声信号去噪及特征提取方法

刘夏扬, 李晶, 赵国新, 刘昱, 雷琦

(北京石油化工学院信息工程学院, 北京 102617)

摘要: 针对由于复杂环境条件下的船舶噪声信号识别度低的问题, 提出了一种改进的变分模式分解(Improved Variational Mode Decomposition, IVMD)、反向排列熵(Reverse Permutation Entropy, RPE)、加权排列熵(Weighted Permutation Entropy, WPE)和能量比相结合的船舶噪声信号识别分类方法。该方法利用 IVMD 将信号分解为若干本征模态函数(Intrinsic Mode Function, IMF); 再利用 RPE 对 IMF 进行筛选, 得到敏感 IMF, 实现去噪过程; 最后计算 IMF 的 WPE 并与各个 IMF 的能量比构建特征向量, 建立长短期记忆网络(Long Short-Term Memory, LSTM)进行识别分类。实验结果表明, 与经验模态分解相比, 文中提出的基于 IVMD-RPE 的船舶噪声信号去噪及特征提取方法能有效减少环境噪声的影响, 提高信噪比, 对船舶噪声目标信号识别分类的准确率更高。

关键词: 变分模式分解(VMD); 反向排列熵(RPE); 长短期记忆网络(LSTM)

中图分类号: TM911.7

文献标志码: A

文章编号: 1000-3630(2023)-03-0297-09

Ship signal denoising and feature extraction based on IVMD-RPE

LIU Xiayang, LI Jing, ZHAO Guoxin, LIU Yu, LEI Qi

(College of Information Engineering, Beijing Institute of Petrochemical Technology, Beijing 102617, China)

Abstract: Aiming at the practical problem of low recognition degree of ship-radiated noise under complex environmental conditions, a method combining improved variational mode decomposition (IVMD), reverse permutation entropy (RPE), weighted permutation entropy (WPE) and energy ratio is proposed for ship noise signal recognition and classification. In this method, IVMD is used to decompose the signal into several intrinsic mode functions (IMFs), RPE is used to screen IMFs to obtain sensitive IMFs and realize the denoising process, and WPE of IMF is calculated and compared with the energy ratio of each IMF. Finally, the feature vector is constructed and the long short-term memory (LSTM) network is established for recognition and classification. The experimental results show that, compared with the empirical mode decomposition, the proposed method based on IVMD and RPE can effectively reduce the influence of environmental noise, improve the signal-to-noise ratio, and have a higher accuracy in the identification and classification of ship noise signals.

Key words: variational mode decomposition (VMD); reverse permutation entropy (RPE); long short term memory (LSTM)

0 引言

作为水下探测技术的一部分, 舰船噪声信号去噪与特征提取的研究对于准确识别敌方目标等国防领域具有重要的理论和实践意义^[1]。船舶噪声信号包含了较多的船舶特征参数, 是衡量船舶性能的重要指标^[2]。因此, 船舶噪声信号去噪和特征提取是

船舶目标识别的关键技术。由于复杂海洋噪声的存在, 真实信号受到信道干扰, 对目标信号的检测、识别有较大影响。如何有效对船舶噪声信号进行去噪和特征提取一直是各国研究的重点和难点。

由于辐射噪声信号是非平稳的、非线性的, 传统的信号处理算法不能有效地处理噪声信号^[3]。针对该类信号, 通常采用经验模式分解和小波分解等时频分析方法进行分析^[4]。经验模态分解(Empirical Mode Decomposition, EMD)可以根据局部特征将多分量信号分解为一系列具有物理意义的本征模态函数(Intrinsic Mode Function, IMF), 相较于传统的傅里叶分析, 能够较好地表征原始信号^[5]。但经验模态分解存在模态混淆和端点效应等问题^[6]。为了解

收稿日期: 2022-01-18; 修回日期: 2022-04-24

基金项目: 国家自然科学基金青年基金(51405023)。

作者简介: 刘夏扬(1995—), 女, 陕西咸阳人, 硕士研究生, 研究方向为信号处理、工业大数据。

通信作者: 李晶, E-mail: bipt_lijing@bipt.edu.cn

决模态混叠问题, Wu等在2009年提出了一种改进的集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)算法, 该算法通过反复添加白噪声, 可以有效降低模态混叠程度^[7]。但EEMD算法存在严重的伪分量, 缺乏数学理论基础, 鲁棒性较差^[8]。针对这一问题, Chen等提出了一种基于改进的自适应噪声互补集成经验模态分解(Improved Complementary Ensemble Empirical Mode Decomposition with Adaptive Noise, ICEEMDAN)、归一化互信息(normalized Mutual Information, norMI)和多尺度改进排列熵(Multiscale Improved Permutation Entropy, MIPE)的特征提取方法, 该方法将识别率提高到了90.67%^[9], 但仍有提升空间。

变分模式分解(Variational Mode Decomposition, VMD)算法是一种分析非线性非平稳信号的非递归算法。VMD算法由Dragomiretskiy等首先提出, 通过构造并求解约束变分问题, 自适应地将复杂信号进行分解, 有效地避免了EMD、EEMD等方法中的过包络、边界效应等问题^[10]。文献[11]采用了VMD算法和基于波动的频散熵对船舶噪声信号进行分析, 通过计算每个能量最高IMF的频散熵与原始信号频散熵的差, 来选择信号主导的频散熵(IMF由EMD分解获得)进行船舶噪声的识别, 但在环境噪声的干扰下, 该方法的识别性能不佳。Li等^[12]采用排列熵(Permutation Entropy, PE)作为复杂度特征, 结合EMD算法和VMD算法提取船舶噪声的复杂度特征, 经过验证, 这两种特征提取算法都优于传统的特征提取算法^[13]。

根据以上分析, 本文利用中心频率方差与反向排列熵对VMD算法进行改进, 并结合加权排列熵及IMF能量比进行特征提取。通过该方法对仿真信号、真实船舶噪声信号进行提取, 实验结果表明该方法的有效性。

1 基本原理

1.1 VMD算法原理及改进

VMD算法是一种分析非线性非平稳信号的非递归算法, 其分解过程即为变分问题的求解过程。该算法将原始信号分解为指定数量的本征模态函数分量, 实现了信号从低频到高频的有效分离^[14]。在该算法中, IMF被定义为一个中心频率为 f_k 、有带宽限制的调幅-调频函数。假设将指定信号 $s(t)$ 分解为 K 个IMF分量 $I_k(t)$, 使得每个模态的估计带宽之和最小, 且各个模态之和等于输入信号 $s(t)$ 。其模型为^[15]

$$\begin{cases} \min_{\{I_k, f_k\}} \left\{ \sum_k \left\| \partial_t \left[\left(\partial(t) + \frac{j}{\pi t} \right) \times I_k(t) e^{-j2\pi f_k t} \right] \right\|_2^2 \right\} \\ s.t. \sum_k I_k = s(t) \end{cases} \quad (1)$$

式中: $\delta(t)$ 为单位脉冲函数。

通过对式(1)中引入二次惩罚因子 α 和拉格朗日惩罚因子 $\lambda(t)$, 将约束变分问题转化为非约束变分问题:

$$\begin{aligned} (\{I_k\}, \{f_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left[\left(\partial(t) + \frac{j}{\pi t} \right) \times I_k(t) e^{-j2\pi f_k t} \right] \right\|_2^2 + \\ & \left\| s(t) - \sum_k I_k(t) \right\|_2^2 + \left\langle \lambda(t), s(t) - \sum_k I_k(t) \right\rangle \end{aligned} \quad (2)$$

利用交替方向乘子法, 通过对 I_k^{n+1} 、 f_k^{n+1} 、 λ^{n+1} 的迭代更新, 求取增广拉格朗日惩罚因子中的鞍点, 获得约束变分模型的最优解:

$$\hat{I}_k^{(n+1)}(f) = \frac{\hat{s}(f) - \sum_{i \neq k} \hat{I}_i(f) + \frac{1}{2} \hat{\lambda}(f)}{1 + 2\alpha(f - f_k)^2} \quad (3)$$

$$f_k^{(n+1)} = \frac{\int_0^\infty 2\pi f |\hat{I}_k(f)|^2 df}{\int_0^\infty |\hat{I}_k(f)|^2 df} \quad (4)$$

$$\hat{\lambda}^{(n+1)}(f) = \lambda^n(f) + \varepsilon \left[\hat{s}(f) - \sum_k \hat{I}_k^{(n+1)}(f) \right] \quad (5)$$

算法收敛条件如式(6), 其中 a 为收敛精度:

$$\frac{\sum_k \left\| \hat{I}_k^{(n+1)} - I_k^n \right\|_2^2}{\left\| I_k^n \right\|_2^2} < a \quad (6)$$

分解模态数 K 是VMD算法中的重要参数, 其取值是关键。若 K 大于有用成分的个数, 会出现过分解现象; 若 K 过小, 则会出现有用数据分解不充分的现象^[16]。针对这一问题, 本文通过中心频率方差来确定 K 的最优值, 方差最大意味着IMF中心频率之间的差值最大。当VMD出现过分解时, 相邻的IMF分量的中心频率是接近的。计算分解后各IMF分量的反向排列熵, 利用反向排列熵对IMF分量进行筛选, 最终得到改进的变分模式分解(Improved Variational Mode Decomposition, IVMD)的最优分量。

1.2 排列熵算法

1.2.1 反向排列熵

反向排列熵(Reverse Permutation Entropy, RPE)是PE的一种新形式。RPE的值代表了时序信号与白噪声之间的距离^[17]。

VMD将信号分解为若干个IMF分量后, 有效船舶信号占比较大, 但仍有部分IMF分量与原始信号的相关性较低, 故本文通过计算每一个IMF分量

的反向排列熵来确定其是否包含重要信息。下面介绍反向排列熵的定义^[18]。

输入是一个长度为 N 的时间序列 \mathbf{X} , 嵌入维数 $m>2$, 延迟时间 τ , 然后从时间序列 \mathbf{X} 中提取长度为 m 的所有可能的 $N-(m-1)$ 个子序列, 则 \mathbf{X} 可以映射到:

$$\mathbf{X}_i^{(m)} = \{x(i), x(i+\tau), \dots, x[i+(m-1)\tau]\},$$

$$i = 1, 2, \dots, N-(m-1)\tau \quad (7)$$

接着 \mathbf{X} 按照递增顺序重新排列:

$$\{x[i+(j_1-1)\tau], x[i+(j_2-1)\tau], \dots, x[i+(j_m-1)\tau]\} \quad (8)$$

如果有两个元素相等:

$$x[i+(j_1-1)\tau] = x[i+(j_2-1)\tau] \quad (9)$$

则排列顺序为

$$\{x[i+(j_1-1)\tau], x[i+(j_2-1)\tau]\}, j_1 \leq j_2 \quad (10)$$

对于时间序列 \mathbf{X} 来说, 每个向量 \mathbf{x} 都可表示为

$$\mathbf{X}_i = [j_1 j_2 \dots j_m] \quad (11)$$

每个符号序列的概率为 P_1, P_2, \dots, P_i , 时间序列 \mathbf{X} 的RPE可根据香农熵的形式定义为

$$E_{RP}(m) = \sum_{j=1}^K (P_j - \frac{1}{m!})^2 = \sum_{j=1}^K P_j^2 - \frac{1}{m!} \quad (12)$$

当 $P_j = \frac{1}{m!}$ 时, E_{RP} 取得最小值0, 即时间序列 \mathbf{X} 与白噪声的距离为0。与排列熵相比, RPE具有更强的噪声识别能力^[18]。

1.2.2 加权排列熵

加权排列熵 (Weighted Permutation Entropy, WPE)的计算方法如下^[19]。根据式(7)~(9)计算子序列, 求得子序列后, 接着计算每个子序列的权重值 ω_i :

$$\omega_i = \frac{1}{m} \sum_{l=1}^m \{x[i+(l-1)\tau] - \bar{X}_i^{(m)}\}^2 \quad (13)$$

$$\bar{X}_i^{(m)} = \frac{1}{m} \sum_{l=1}^m x[i+(l-1)\tau] \quad (14)$$

权重值 ω_i 和排列模式 s_i 即可表示任意子序列 $X_i^{(m)}$ 的特征信息。对于该时间序列 \mathbf{X} 共有 K 种排列模式, 每种排列模式 s_i 的加权概率值为

$$P_{\omega}(s_k) = \frac{\sum [\omega_i | 1 \leq i \leq N-(m-1)\tau, i \in Z^+, N(X_i^{(m)})]}{\sum \omega_i} \quad (15)$$

则WPE的计算公式为

$$E_{WP}(m) = - \sum_{k=1}^K P_{\omega}(s_k) \ln P_{\omega}(s_k) \quad (16)$$

1.3 能量比算法

选用IMF分量与原始信号的能量比(Energy Ra-

tio, ER)以及WPE加权能量比构建特征向量^[20], 进行分类实验。由帕斯瓦尔定理, 信号 $x(t)$ 的总能量为

$$E = \sum_{n=1}^N x_n^2 \quad (17)$$

式中: x_n 表示第 n 个采样点的幅值。

信号去噪后经过EMD后得到 n 阶IMF分量, 对保留的IMF进行快速傅里叶变换(Fast Fourier Transform, FFT), 获得各个IMF分量的幅度谱, 则各阶IMF分量的能量为

$$E_i = \frac{1}{N} \sum_{n=1}^N A_{in}^2 \quad (18)$$

其中: A_{in} 表示第 i 阶IMF分量幅度谱中的幅度, N 为信号采样点个数, 则各阶IMF分量的能量 E_i 与信号总能量 E 的比为

$$b_i = \frac{E_i}{E} \quad (19)$$

1.4 长短期记忆网络

长短期记忆(Long Short-Term Memory, LSTM)网络是目前实际应用中较高效的序列模型。该网络是由循环神经网络(Recurrent Neural Network, RNN)改进, 即在循环神经网络的基础上加入一个用来存储长依赖数据信息的记忆块, 当有新的信息提供时, 允许网络学习何时忘记以前的记忆状态, 或何时更新隐藏的状态。记忆块是存储网络暂时状态的记忆单元, 在每个记忆块中, 由输入门、输出门、遗忘门和记忆细胞组成。输入门控制进入记忆细胞的信息多少, 而输出门决定进入下一记忆细胞的信息, 遗忘门调节细胞的自我循环连接。这种门控机制使得网络能够更好地发现和利用长期的环境, 这对于RNN处理长时序样本时产生的梯度爆炸及梯度消失的问题有着很好的解决效果。LSTM内部结构单元如图1所示。




图1 LSTM内部记忆单元
Fig.1 Internal memory unit of LSTM

LSTM隐藏层输出的迭代公式为^[21]

$$i_t = \sigma(\mathbf{W}_{xi}x_t + \mathbf{W}_{hi}h_{t-1} + \mathbf{W}_{ci}c_{t-1} + \mathbf{b}_i) \quad (20)$$

$$f_i = \sigma(W_{xf}x_i + W_{hf}x_{i-1} + W_{cf}c_{i-1} + b_f) \quad (21)$$

$$c_i = f_i c_{i-1} + i_i \tanh(W_{xc}x_i + W_{hc}h_{i-1} + b_c) \quad (22)$$

$$o_i = \sigma(W_{xo}x_i + W_{ho}h_{i-1} + W_{co}c_i + b_o) \quad (23)$$

$$h_i = o_i \tanh(c_i) \quad (24)$$

其中： x_i 为输入， o_i 为输出， σ 为sigmoid激活函数； i_i 为输入门，首先，输入门中的sigmoid层决定更新值，接着tanh层创建 c_{i-1} ，单元状态更新； f_i 为遗忘门，该过程可以决定单元状态中哪些信息被保留， h_{i-1} 和 x_i 输出范围为0~1，1表示保留全部信息，0表示丢掉所有信息； c_i 为细胞激活向量， h_i 为隐藏向量， W 为权重矩阵 b_f 、 b_c 、 b_o 分别为输入门、遗忘门、细胞激活向量和输出门的偏置。

2 特征提取方法流程

本文提出了一种融合IVMD、RPE、WPE和能量比的船舶噪声信号特征提取方法，该方法的流程图如图2所示，主要步骤如下：

(1) 设初始参数 $K=2$ ，依次使 $K=K+1$ ，计算不同 K 值下VMD分解得到的各个IMF分量的中心频率方差值；

(2) 选择中心频率最大方差值所对应的 K 作为VMD的最优参数；

(3) 对原始信号进行VMD分解，得到一组IMF分量；

(4) 提取每个IMF分量的RPE并对IMF分量进

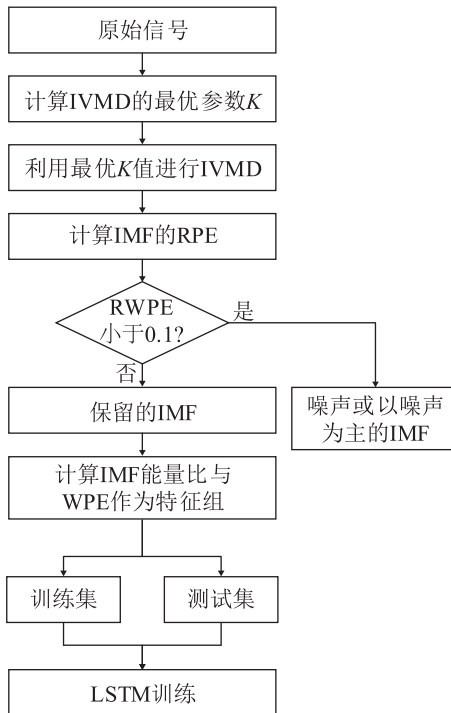


图2 特征提取方法流程

Fig.2 Flow chart of feature extraction

行筛选，得到IVMD最优IMF分量；

(5) 计算每个保留的IMF分量的WPE以及能量比作为分类的特征向量；

(6) 将获得的特征向量随机分成训练数据，通过LSTM神经网络进行训练分类，实现船舶噪声的分类识别。

3 仿真信号特征提取及分析

合成信号 S 如式(25)，信号长度为1 s，采样频率为1 000 Hz，并在合成信号叠加高斯白噪声 η 构成仿真信号 y' ， y' 的合成如式(26)， y' 信噪比为8 dB。

$$S = \begin{cases} s_1 = \cos(2\pi t) \\ s_2 = \cos(10\pi t) \\ s_3 = \cos(20\pi t) \end{cases} \quad (25)$$

$$y' = s_1 + s_2 + s_3 + \eta \quad (26)$$

合成信号如图3所示。加噪信号如图4所示。







图3 合成信号及其各分量

Fig.3 Synthetic signal and its various components




图4 加噪信号波形
Fig.4 Waveform of signal with noise

为了验证IVMD对信号分解的有效性，分别利用EMD和IVMD对仿真信号 y' 进行分解并重构。表1为两种分解方法的各IMF分量与加噪信号的相关系数。由表1对照图5的EMD分解图与图6的IVMD分解图可以看出，信号经IVMD分解后能够明显地看到 s_1 、 s_2 和 s_3 对应的是IMF7、IMF6和IMF5，且表1中有效IMF与加噪信号的相关系数相比于冗余IMF有明显差异。故IVMD能够准确地分解出隐藏在复合信号中的单频分量，具有较佳的分解性能。

由图5的EMD分解结果，与 s_1 、 s_2 、 s_3 对比发现，IMF2出现了明显的模态混淆现象，IMF4出现

表1 EMG和IVMD分解的各IMF与加噪信号的相关系数
Table 1 Correlation coefficients of the noisy signal with various IMFs decomposed by EMG and IVMD

IMF阶数	EMD	IVMD
1	0.367 9	0.153 2
2	0.649 6	0.157 9
3	0.506 9	0.167 9
4	0.340 4	0.156 1
5	0.264 9	0.544 2
6	0.031 4	0.550 2
7	—	0.561 1

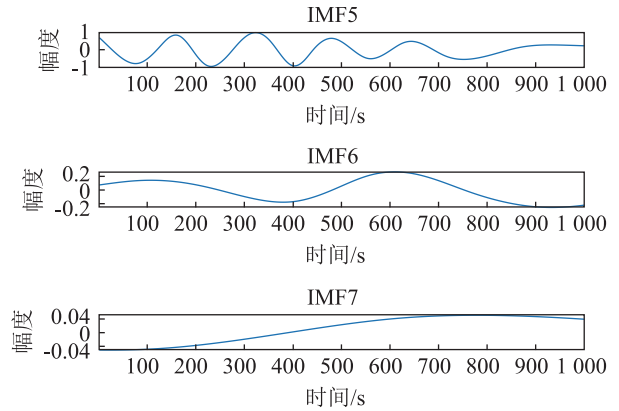



图5 原始信号的EMD分解图
Fig.5 EMD decomposition of original signal

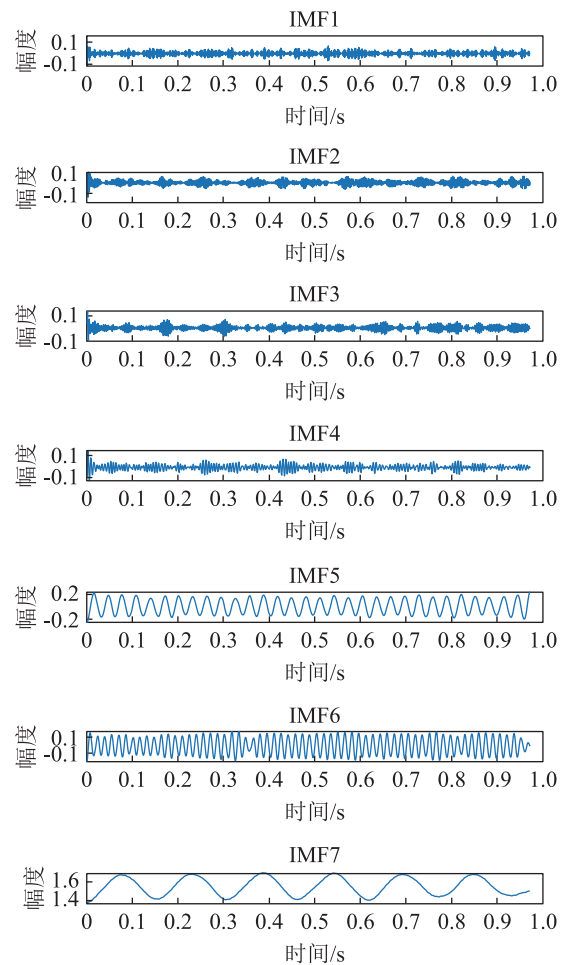


图6 原始信号的IVMD分解图
Fig.6 IVMD decomposition of original signal

了明显的端点效应，受以上原因影响，导致均方根误差(Root Mean Square Error, RMSE)数值较高，相关系数的数值混乱^[22]。相较于EMD，IVMD在有干扰的情况下并没有出现模态混淆的情况。表2为重构后的信号与原始信号的RMSE对比，由表2可以看出，IVMD的去噪能力相对较好。

为了验证 K 的取值对RMSE的影响，根据文献中的设定将 K 分别为5~20对仿真信号 y' 进行IVMD

表2 EMD和IVMD的重构信号的均方根误差
Table 2 RMSEs of the reconstructed signals by EMD and IVMD

算法	RMSE
原始信号	0.490 4
EMD	0.429 0
IVMD	0.340 7

分解, 惩罚参数 α 分别取500和2 000, 验证 α 对 K 的影响^[6]。为提高准确度, 寻优10组求取平均值确定 K 。对仿真信号进行VMD分解, 计算每次分解后IMF中心频率的均方根误差。最大均方根误差的参数选为最优参数 K 。不同 K 对应的均方根误差RMSE如图7所示。由图7可以看出, K 值的确定与 α 的大小关系不明显。当 $K=7$ 时, 分解后各IMF中心频率的均方根误差最大。此后方差开始下降, 因此 $K=7$ 为IVMD的最优参数。




图7 惩罚参数 α 为500和2 000时 K 值与IVMD分解的IMF中心频率均方根误差的关系曲线

Fig.7 K versus center frequency RMSE of IMF decomposed by IVMD for the penalty parameter $\alpha=500$ and 2 000

由于VMD算法相当于自适应维纳滤波器组, 当信号的分解个数较多时, 原始信号中一些重要信息将会被滤掉丢失, 相邻模态分量的频率中心会比较接近, 产生频率混叠。表3为不同 K 值时各IMF的中心频率, 可以看出在 $K=8$ 时, IMF6和IMF7的中心频率318.7和319.5 Hz较接近, 可能会出现模态混叠, 模态个数选为7较合适, 与方差计算结果相同。

由于分解得到的IMF分量并不全是有效IMF分

表3 不同 K 值时IVMD算法分解的IMF中心频率
Table 3 Center frequencies of IMFs decomposed by IVMD of different K values

K	中心频率/Hz							
	IMF1	IMF2	IMF3	IMF4	IMF5	IMF6	IMF7	IMF8
6	8.206	9.823	103.3	243.2	337.9	439.4		
7	5.369	9.920	53.69	196.7	287.8	374.4	454.3	
8	5.319	51.03	99.53	181.7	256.9	318.7	319.5	461.9

量, 有些成分是噪声, 需在特征提取之前剔除。为了验证IVMD-RPE算法的去噪性能, 计算两种方法分解后的IMF分量的RPE, 时延参数和嵌入维数分别为1和3^[23]。表4列出了各IMF分量的RPE, 从表4中可以看出, 有效IMF的RPE比噪声IMF分量的RPE高一个数量级, 因此IVMD-RPE算法更容易识别噪声IMF分量。

由表4可知, 除了IMF1分量之外, 所有的噪声几乎都被滤除。将RPE的阈值设置为0.1, 为了证明IVMD算法的去噪性能, 将保留的有效IMF进行信号重构, 其与噪声信号的信噪比及均方根误差如表5所示。由表5可以看出, IVMD-RPE算法的信噪比有明显的提升, RMSE指标较好, 证明该算法具有较好的去噪性能, 并且解决了阈值选择的问题。

表4 EMG和IVMD分解的各IMF的RPE值
Table 4 RPE values of each IMF decomposed by EMG and IVMD

IMF	RPE	
	EMD	IVMD
1	0.144 5	1.008 9
2	0.748 7	0.074 9
3	0.251 7	0.002 4
4	0.099 5	0.009 1
5	0.562 4	0.155 1
6	0.337 4	0.164 2
7	—	0.138 2

表5 RPE的阈值为0.1时两种算法重构信号的信噪比与均方根误差

Table 5 SNRs and RMSEs of the reconstructed signals by the two algorithms when the threshold of RPE is 0.1

算法	信噪比/dB	RMSE
原始信号	7.950 6	0.490 4
EMD-RPE	10.800 8	0.302 0
IVMD-RPE	15.306 0	0.231 0

4 实验分析

本文使用了维戈大学提供的名为ShipsEar的真实水下船只噪声数据库^[24], 并从中选出三种类别不同的船只噪声作为实验数据集进行训练, 简称为A、B、C类, 每个样本分别采集于不同的时间和环境。选取的各类数据的原始时域波形如图8所示。

船舶信号在传播过程中不可避免会被噪声所干扰, 因此, 为了实现提高船舶信号的特征提取的准确率, 需要对船声信号进行去噪处理^[25]。信号预处理的步骤如下:




图8 A、B、C三类声学信号时域图

Fig.8 Time domain waveforms of three kinds of signals A, B and C

设初始参数 $K=2$ ，根据经验^[6]，本文中的 α 取2 000，依次使 $K=K+1$ ，计算不同 K 值下VMD分解得到的各IMF分量的中心频率方差值，选取方差最大的 K 值作为最优参数。经计算，A、B、C类在 $K=15$ 时方差最大。

计算 K 为15时各IMF分量的反向排列熵。图9为A、B、C三类信号分解后各IMF分量的RPE值，由于高频IMF分量与低频IMF分量的RPE相差几乎一个数量级，且有效信息都含括在高频IMF分量中，故选取0.1作为阈值。从图9可以看出，当

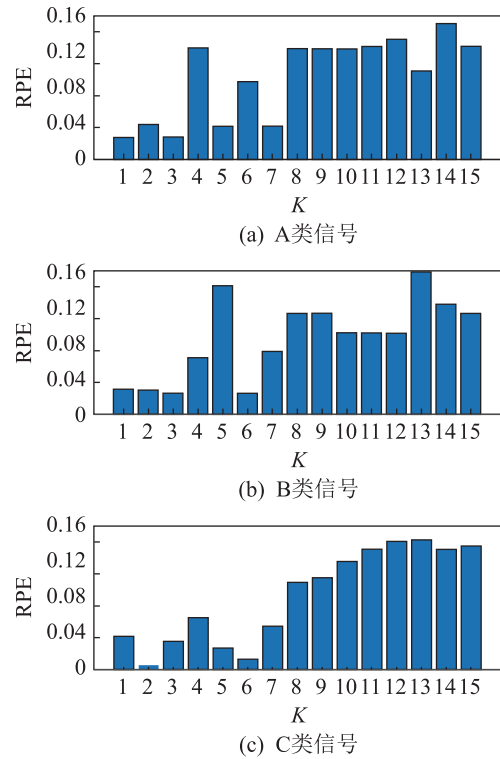


图9 三类信号分解后各IMF的RPE值

Fig.9 RPE values of various IMF of the three kinds of signals after decomposition

RPE的阈值设置为0.1时，A、B、C类的噪声IMF分量和其余IMF分量都可以清晰地区分出来。将RPE阈值设置为0.1对IMF分量进行筛选，可以看出噪声被大部分滤除。IMF1至IMF8大部分为噪声模态分量，IMF9至IMF15为有效模态分量。图10为A类船只声学信号的IVMD分解。

本文在每类船只信号的样本中各选取随机500个样本作为这三类信号的数据集进行处理和识别，信号采样率为50 kHz。从三类样本中随机选取1 200个样本作为训练集，其余300个样本作为测试

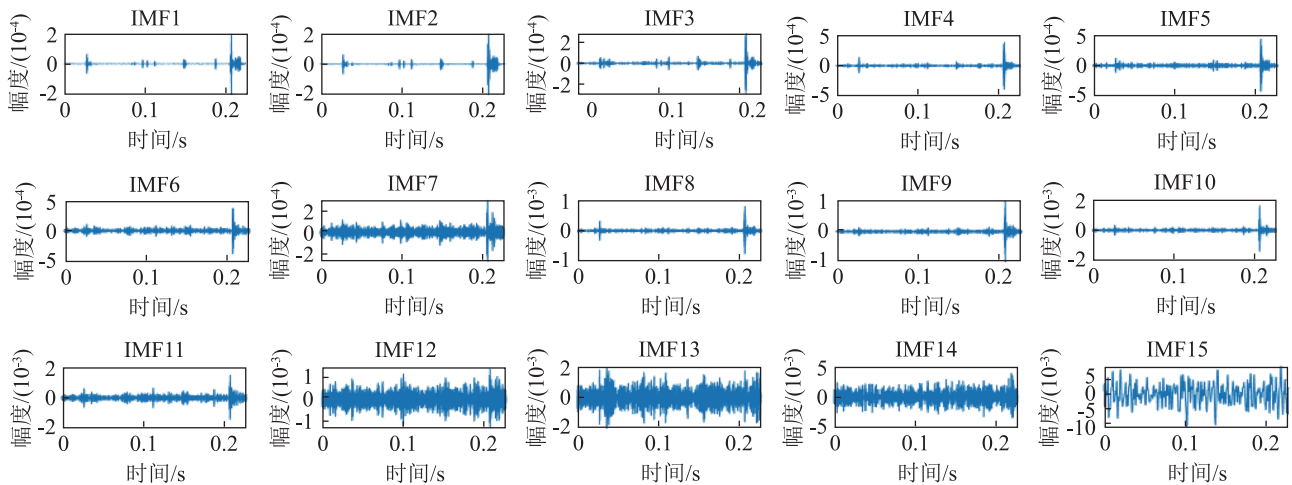


图10 A类船只声学信号的IVMD分解

Fig.10 IVMD decomposition of Class A signal

数据, 利用 LSTM 网络进行分类训练, 网络包含 5 个 LSTM 网络层和 1 个全连接层, 实验参数为: 时间序列长度 T 取 1 000, 隐藏层结构为 1 层; 隐藏层单元个数依次选取 20、50、80、110, 学习率选取 0.01, 优化器使用 Adam 进行实验, 选取最优隐藏层个数; 最大迭代次数取 50, 每批次样本数取 100。分别使用 EMD、EMD-RPE、IVMD-RPE 三种算法对三类船舶信号进行分解去噪, 并计算加权排列熵和能量比作为特征向量。

计算有效 IMF 分量的 WPE 和能量比作为特征向量进行分类训练, 分类结果如表 6 所示。

从表 6 可以看出, 未经 RPE 进行去噪的 EMD 方法的对各信号的识别率较低, 识别率仅为 75.3%, 这说明了信号去噪的重要性。本文提出的 IVMD-RPE 方法与 EMD-RPE 方法相比, 识别精度相对较高, 验证了 IVMD 算法的预处理优势。

为了验证 IVMD-RPE 的去噪效果, 对原始信号分别加入不同信噪比高斯白噪声进行分类训练, 分类结果如表 7 所示, 表中的原始信号表示所得到的无高斯噪声的信号。在不同信噪比时 A 类、B 类船只均能被有效识别, C 类船只的识别率由 93.5% 下降到 83%, 且随着信噪比的降低, 系统的识别率下降不明显。说明该算法对噪声影响的鲁棒性较强。

表 6 不同算法对三类信号的识别率和分类准确率
Table 6 Recognition rates and classification accuracies of different algorithms for the three kinds of signals

算法	识别率/%			准确率/%
	A 类	B 类	C 类	
EMD	60	82	84	75.3
EMD-RPE	100	98.0	91.0	96.4
IVMD-RPE	100	100	93.5	98.5

表 7 不同信噪比下 IVMD-RPE 算法对三类信号的识别率和分类准确率

Table 7 Recognition rates and classification accuracies of IVMD-RPE algorithm for the three kinds of signals under different SNRs

信号类型	识别率/%			准确率/%
	A 类	B 类	C 类	
原始信号	100	100	93.5	98.5
信噪比 20 dB	100	100	86.5	95.5
信噪比 15 dB	100	98.0	83.0	93.6

5 结论

为了提取能表征船舶辐射噪声的固有特征, 本文建立了一种改进的变分模式分解法, 利用计算的频率中心频率均方根误差来确定 VMD 的 K 值, 并通过

计算各 IMF 分量的 RPE 对有效 IMF 分量进行筛选。利用该算法对信号进行处理的结果表明, 在噪声干扰下, IVMD 能有效提取到复合信号的较高精度信号分量, 解决了阈值选择的问题, 有效地抑制了模态混淆、端点效应等问题, 验证了 IVMD-RPE 的分解结果具有良好的精度, 能够有效识别噪声, 去噪能力有明显提高。利用有效 IMF 分量的加权排列熵和能量比组成真实船舶噪声信号特征向量进行研究。实验结果表明, 去噪后有效 IMF 分量的 WPE 和能量比作为特征向量准确率达到 98.5%, 相较于 EMD 算法, 准确率提高了 23.2 个百分点, 相较于 EMD-RPE 算法准确率提高了 2.1 个百分点。因此, 本文方法能有效适用于船舶噪声信号的特征提取, 具有很好的应用前景。

本文中实验所得的各项参数仅适用于本文所使用的数据集, 针对其他数据集的处理, 参数需根据实验结果进行确定。对于参数的选择后续会做进一步的研究, 增加算法的适用性。文中仅对模态数进行了讨论, 后续将对模态数和二次惩罚项同时进行优化, 以进一步提高 IVMD 的分解精度; 在选择表征信号的特征向量选择方面将做进一步的研究。

参 考 文 献

- [1] DAS A, KUMAR A, BAHL R. Marine vessel classification based on passive sonar data: the cepstrum-based approach[J]. IET Radar, Sonar & Navigation, 2013, 7(1): 87-93.
- [2] LI Y X, LI Y A, CHEN X, et al. Denoising and feature extraction algorithms using NPE combined with VMD and their applications in ship-radiated noise[J]. Symmetry, 2017, 9(256): 1-18.
- [3] YANG S, LI Z S, WANG X L. Ship recognition via its radiated sound: the fractal based approaches[J]. The Journal of the Acoustical Society of America, 2002, 112(1): 172-177.
- [4] NIU F, HUI J, ZHAO A, et al. Application of SN-EMD in mode feature extraction of ship radiated noise[J]. Mathematical Problems in Engineering, 2018, 2018.
- [5] XIE D, ESMAIEL H, SUN H X, et al. Feature extraction of ship-radiated noise based on enhanced variational mode decomposition, normalized correlation coefficient and permutation entropy[J]. Entropy, 2020, 22(4): 468.
- [6] 徐帆, 常建华, 刘秉刚, 等. 基于 VMD 的激光雷达回波信号去噪方法研究[J]. 激光与红外, 2018, 48(11): 1443-1448. XU Fan, CHANG Jianhua, LIU Binggang, et al. De-noising method research for lidar echo signal based on variational mode decomposition[J]. Laser & Infrared, 2018, 48(11): 1443-1448.
- [7] WU Z H, HUANG N. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1793-5369.
- [8] HUANG N E, SHEN S S. Hilbert-Huang transform and its applications[M]. Singapore: World Scientific, 2005.
- [9] CHEN Z, LI Y A, CAO R J, et al. A new feature extraction method for ship-radiated noise based on improved CEEM-DAN, normalized mutual information and multiscale im-

- proved permutation entropy[J]. *Entropy*, 2019, **21**(6): 624.
- [10] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition[J]. *IEEE Transactions on Signal Processing*, 2014, **62**(3): 531-544.
- [11] YANG H, ZHAO K, LI G H. A new ship-radiated noise feature extraction technique based on variational mode decomposition and fluctuation-based dispersion entropy[J]. *Entropy*, 2019, **21**(3): 235.
- [12] LI Y X, LI Y A, CHEN X, et al. A novel feature extraction method for ship-radiated noise based on variational mode decomposition and multi-scale permutation entropy[J]. *Entropy*, 2017(19): 342.
- [13] YANG H, LI Y, LI G. Energy analysis of ship-radiated noise based on ensemble empirical mode decomposition[J]. *Shock Vib*, 2015, **34**: 55-59.
- [14] 罗亦泳, 姚宜斌, 黄城, 等. 基于改进VMD的变形特征提取与分析[J]. *武汉大学学报(信息科学版)*, 2020, **45**(4): 612-619.
LUO Yiyong, YAO Yibin, HUANG Cheng, et al. Deformation feature extraction and analysis based on improved variational mode decomposition[J]. *Geomatics and Information Science of Wuhan University*, 2020, **45**(4): 612-619.
- [15] 郑小霞, 周国旺, 任浩翰, 等. 基于变分模态分解和排列熵的滚动轴承故障诊断[J]. *振动与冲击*, 2017, **36**(22): 22-28.
ZHENG Xiaoxia, ZHOU Guowang, REN Haohan, et al. A rolling bearing fault diagnosis method based on variational mode decomposition and permutation entropy[J]. *Journal of Vibration and Shock*, 2017, **36**(22): 22-28.
- [16] XIE D R, SUN H X, QI J. A new feature extraction method based on improved variational mode decomposition, normalized maximal information coefficient and permutation entropy for ship-radiated noise[J]. *Entropy*, 2020, **22**(6): 620.
- [17] LI Y X, LI Y A, CHEN X, et al. Denoising and feature extraction algorithms using NPE combined with VMD and their applications in ship-radiated noise[J]. *Symmetry*, 2017, **9**(11): 256.
- [18] BANDT C, HORNERO R. A new kind of permutation entropy used to classify sleep stages from invisible EEG microstructure[J]. *Entropy*, 2017, **19**(5): 197.
- [19] FADLALLAH B, CHEN B, KEIL A, et al. Weighted-permutation entropy: a complexity measure for time series incorporating amplitude information[J]. *BMC Genomics*, 2013, **87**(2): 022911.
- [20] 贾春花, 郭敏. 基于HHT方法的果蝇鸣声特征提取及分类[J]. *云南大学学报(自然科学版)*, 2011, **33**(2): 152-157.
JIA Chunhua, GUO Min. Feature extraction and classification of fruit fly's flight sound based on HHT[J]. *Journal of Yunnan University (Natural Sciences Edition)*, 2011, **33**(2): 152-157.
- [21] YU Y, SI X S, HU C H, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. *Neural Computation*, 2019, **31**(7): 1235-1270.
- [22] 戴婷, 张榆锋, 章克信, 等. 经验模态分解及其模态混叠消除的研究进展[J]. *电子技术应用*, 2019, **45**(3): 7-12.
DAI Ting, ZHANG Yufeng, ZHANG Kexin, et al. The research progress of empirical mode decomposition and mode mixing elimination[J]. *Application of Electronic Technique*, 2019, **45**(3): 7-12.
- [23] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series[J]. *Physical Review Letters*, 2002, **88**(17): 174102.
- [24] SANTOS-DOMÍNGUEZ D, TORRES-GUIJARRO S, CARDENAL-LÓPEZ A, et al. ShipsEar: An underwater vessel noise database[J]. *Applied Acoustics*, 2016, **113**: 64-69.
- [25] BAO F, LI C, WANG X L, et al. Ship classification using nonlinear features of radiated sound: an approach based on empirical mode decomposition[J]. *The Journal of the Acoustical Society of America*, 2010, **128**(1): 206-214.