【引用格式】吴昌灵，李梓华，陈哲. 基于 SGMD 和 MIPE 的舰船辐射噪声特征提取方法研究[J]. 数字海洋与水下攻防，2025，8（5）：627-635.

基于 SGMD 和 MIPE 的舰船辐射噪声特征提取方法研究

吴昌灵，李梓华，陈　哲*

（桂林电子科技大学 信息与通信学院，广西 桂林 541004）

摘　要　针对复杂环境下低信噪比水声信号特征提取的难点，提出一种基于辛几何模态分解（SGMD）、多尺度改进排列熵（MIPE）舰船辐射噪声特征提取方法。该方法利用 SGMD 对 3 类舰船辐射噪声信号进行降噪，有效抑制噪声干扰并保留信号本质特征；提取 MIPE 特征作为分类的特征参数，并输入概率神经网络（PNN）进行分类识别。实验结果表明：在 0 dB 和 5 dB 低信噪比环境下，所提方法的平均识别率分别达到 96.89%和 99.56%，相较于未降噪处理前分别提升 9.11%和 7.79%，验证了该方法在低信噪比下具备良好的特征稳健性与分类性能。

关键词　辛几何模态分解；多尺度改进排列熵；特征提取；分类识别

中图分类号　TN911.7　　**文献标识码**　A　　**文章编号**　2096-5753(2025)05-0627-09

DOI　10.19838/j.issn.2096-5753.2025.05.013

Feature Extraction of Ship Radiated Noise Based on SGMD and MIPE

WU Changling，LI Zihua，CHEN Zhe*

（School of Information and Communication，Guilin University of Electronic Technology，Guilin 541004，China）

Abstract　To address the challenge of feature extraction from ship radiated noise in complex environments with low signal-to-noise ratio（SNR），a method based on symplectic geometry mode decomposition（SGMD）and multiscale improved permutation entropy（MIPE）is proposed in this paper. The proposed method utilizes SGMD to denoise the radiated noise signals from three types of ships，effectively suppressing noise interference while retaining the intrinsic signal characteristics. Subsequently，the MIPE features are extracted as classification parameters and fed into a probabilistic neural network（PNN）for classification and recognition. Experimental results demonstrate that under low SNR conditions of 0 dB and 5 dB，the average recognition rates of the proposed method reach 96.89% and 99.56%，respectively. These represent significant improvements of 9.11% and 7.79% respectively compared with the results obtained without the denoising process，thereby validating the excellent feature robustness and classification performance of the proposed method under low SNR conditions.

收稿日期：2025-08-31

作者简介：吴昌灵（1997-），男，硕士，助教，主要从事水声信号处理研究。

*通信作者：陈哲（1993-），男，博士，副教授，主要从事水声信号处理研究。

基金项目：国家自然科学基金“水下矢量声场高效稳健方位估计方法研究”（62301179）；广西自然科学基金“水下小孔径超增益高阶矢量声呐应用基础研究”（2025GXNSFFA069010）。

Key words symplectic geometry mode decomposition（SGMD）；multiscale improved permutation entropy（MIPE）；feature extraction；classification and recognition

0 引言

舰船目标识别在海洋环境监测、生态保护、海上导航[1]等诸多海洋领域发挥着关键作用。由于产生机理复杂，受到非均匀、时变、空变、随机的海洋传输介质影响[2]，舰船辐射噪声常伴随非线性、非高斯、非平稳的“三非”特性，且随着“隐身”技术迅速发展，辐射噪声逐年降低[3]，稳健特征提取成为舰船目标识别的难点。

传统的水声信号降噪技术主要包括维纳滤波、局部投影算法、奇异谱分析及主成分分析等，此类方法对复杂“三非”信号的处理能力有限[4]，无法满足实际需求。经验模态分解（Empirical Mode Decomposition，EMD）通过筛选噪声主导的固有模态函数并进行分量重构，可以抑制噪声，常用于非线性、非平稳信号的特征提取与分析[5]。该方法分解过程易受噪声干扰影响，且存在模态混叠现象的问题。集合经验模态分解（Ensemble Empirical Mode Decomposition，EEMD）、互补集成 EMD、掩蔽信号 EMD、均匀相 EMD 等改进方法[6-7]缓解了噪声干扰和模态混叠的问题，但此类方法依赖人工干预的极值点设置，且缺乏严格的数学理论体系支撑。变分模态分解（Variational Mode Decomposition，VMD）是 HUMPHREY 等[8]人基于维纳滤波、希尔伯特变换等数学理论提出的自适应分解方法。VMD 通过全局优化策略有效抑制模态混叠现象，在噪声鲁棒性、模态分离精度及数学理论完备性方面展现出了显著优势。李余兴等人[9]将变分模态分解和支持向量机结合，对 4 类舰船信号的识别率达 94%。但 VMD 需要主观设置预设参数（如 IMF 数量、惩罚因子等），影响了分类降噪的效果，学者们结合群体智能优化算法对 VMD 手动参数设置的问题进行了改进[10]。

XIE 等[11]人提出了辛几何谱分析（Symplectic Geometry Spectrum Analysis，SGSA），利用辛矩阵相似变换保护原信号相空间的结构特性和时间序列完整性的同时活动辛几何分量，在分析非线性、非平稳信号方面具有良好的效果。但 SGSA 需要人为主观设定嵌入维数，设定规则缺乏严格理论支撑。潘海洋等人[12]在 SGSA 的基础上提出了辛几何模态分解（Symplectic Geometry Mode Decomposition，SGMD），该方法自适应设定嵌入维数和终止条件，利用辛矩阵相似变换求解 Hamilton 矩阵的特征值，根据特征向量对信号进行重构，可有效重构模态、去除噪声影响。目前，辛几何模态分解被广泛应用于轴承故障诊断、齿轮箱故障特征提取等非线性和非平稳信号处理[13]，但在水声信号处理领域特别是在消除噪声干扰和提取稳健特征等方面应用极少。

本文针对噪声难消除、稳健特征难提取问题，按照“信号降噪—特征提取—特征训练识别”的解决思路，提出一种基于辛几何模态分解和改进排列熵的舰船辐射噪声特征提取方法。通过辛几何模态分解将原信号分解成多个独立初始分量，对噪声分量和信号分量进行识别、重构，提取多尺度改进排列熵特征，最后将提取特征输入概率神经网络（PNN）进行分类验证，实验结果表明了所提算法的有效性。

1 基于辛几何模态分解的降噪算法

1.1 相空间重构

设一维离散原信号 $\{y_1, y_2, \ldots, y_n\}$，设置嵌入维数 d 和时延 τ，按照 Takens 重构定理[14]进行相空间重构，得到轨迹矩阵 $\boldsymbol{Y}$：

$$\boldsymbol{Y} = \begin{bmatrix} y_1 & y_{1+\tau} & \cdots & y_{1+(d-1)\tau} \\ y_2 & y_{2+\tau} & \cdots & x_{2+(d-1)\tau} \\ \vdots & \vdots & \vdots & \vdots \\ y_m & y_{m+\tau} & \cdots & y_{m+(d-1)\tau} \end{bmatrix} \tag{1}$$

式中，$m = n - (d+1)\tau$。相空间重构时，嵌入维数 d 和时延 τ 的大小对轨迹矩阵 $\boldsymbol{Y}$ 有很大的影响。参考文献[15]提出的方法，通过原信号的功率谱密度（Power Spectral Density，PSD）来估计最大峰值时

的频率 $f_{\max}$，并计算归一化的频率。将阈值设为 10^{-3}，如果归一化的频率大于阈值，$d=1.2\times(F_s/f_{\max})$，否则，$d=n/3$，$F_s$为采样频率，一般情况下 $\tau=1$。

1.2　辛正交矩阵变换

通过对轨迹矩阵 $\boldsymbol{Y}$ 进行自相关分析，得到协方差矩阵 $\boldsymbol{J}=\boldsymbol{Y}^{\mathrm{T}}\boldsymbol{Y}$，进而构造 Hamilton 矩阵 $\boldsymbol{N}$ 为

$$\boldsymbol{N}=\begin{bmatrix}\boldsymbol{J}^{\mathrm{T}} & 0\\ 0 & -\boldsymbol{J}\end{bmatrix} \tag{2}$$

令 $\boldsymbol{W}=\boldsymbol{N}^2$，则 $\boldsymbol{W}$ 和 $\boldsymbol{N}$ 都为 Hamilton 矩阵。构造辛正交矩阵 $\boldsymbol{Q}$，使得：

$$\boldsymbol{Q}^{\mathrm{T}}\boldsymbol{W}\boldsymbol{Q}=\begin{bmatrix}\boldsymbol{B} & \boldsymbol{R}\\ \boldsymbol{0} & \boldsymbol{B}^{\mathrm{T}}\end{bmatrix} \tag{3}$$

式中，$\boldsymbol{B}$ 为上三角矩阵。$\boldsymbol{B}$ 可通过辛正交矩阵对 $\boldsymbol{W}$ 进行变换得到，其特征值为 $\lambda_1,\lambda_2,\ldots,\lambda_d$。根据性质有 $\delta_i=\sqrt{\lambda_i},(i=1,2,\ldots d)$，$\boldsymbol{Q}_i$ 为矩阵 $\boldsymbol{J}$ 对应于 δ_i 的特征向量。则有：

$$\boldsymbol{S}_i=\boldsymbol{Q}_i^{\mathrm{T}}\boldsymbol{J}^{\mathrm{T}},(i=1,2,\ldots d) \tag{4}$$

进而可得：

$$\boldsymbol{Z}_i=\boldsymbol{Q}_i\boldsymbol{S}_i,(i=1,2,\ldots d) \tag{5}$$

得到初分量重构矩阵 $\boldsymbol{Z}$，可写为

$$\boldsymbol{Z}=\boldsymbol{Z}_1+\boldsymbol{Z}_2+\ldots+\boldsymbol{Z}_d \tag{6}$$

1.3　对角平均化

通过对角平均化的式子（7）将 $m\times d$ 阶 $\boldsymbol{Z}_i$ 的初分量还原为 d 组长度为 n 的一维初始辛几何分量（ISGC）x_k：

$$x_k=\begin{cases}\dfrac{1}{k}\displaystyle\sum_{p=1}^{k}z^*_{p,k-p+1} & 1\le k\le d^*\\[2ex] \dfrac{1}{d}\displaystyle\sum_{p=1}^{d^*}z^*_{p,k-p+1} & d^*\le k\le m^*\\[2ex] \dfrac{1}{n-k+1}\displaystyle\sum_{p=k-m^*+1}^{n-m^*+1}z^*_{p,k-p+1} & m^*<k\le n\end{cases} \tag{7}$$

式中：$d^*=\min(m,d)$；$m^*=\max(m,d)$；$n=m+(d-1)\tau$。x_{ij}（$1\le i\le d,1\le j\le \mathrm{d}$）为初分量重构矩阵 $\boldsymbol{Z}_i$ 中的元素，若 $m<d$，则 $Z^*_{ji}=Z_{ij}$，否则 $Z^*_{ij}=Z_{ji}$。通过对角平均后，得到新的时间序列 $X=x_1,x_2,\ldots,x_i,(1\le i\le d)$。所有初始辛几何分量 $x_i(1\le i\le d)$ 之和与原始时间序列相等。

1.4　重构初始辛几何分量

通过对角平均化得到的初始分量 X 含有部分噪声模态，而包含信号特征的分量会集中在前几个初始辛几何分量（ISGC）中，本文通过不同初始辛几何初始分量的能量占比识别噪声分量。其中，信号能量为信号幅值的平方在时间上的积分，则信号 h 的能量表达式为

$$E_h=\int|h(t)|^2\mathrm{d}t \tag{8}$$

经过辛几何模态分解之后，第 i 个初始辛几何分量的能力占比表达式为

$$E_{\mathrm{ISGMD}}(i)=\frac{\int|x_i(t)|^2\mathrm{d}t}{\int|h(t)|^2\mathrm{d}t} \tag{9}$$

将能量占比阈值设置为 0.01，当 $E_{\mathrm{ISGMD}}(i)$ 大于阈值时判别为有用分量 ISGC^k，计算所有分量的能量占比可以获取含有目标信号的初始辛几何分量，进行重组得到降噪后信号。

2　改进排列熵算法

传统的排列熵算法存在忽略了幅值信息的问题，CHEN 等人[16]提出了一种改进排列熵算法（Improved Permutation Entropy，IPE），该算法在排列熵框架上，通过均匀量化算子对重构后的相空间进行符号化，同时考虑了信号的幅值和次序信息，进而获得时间序列更加丰富的潜在“次序模式”。IPE 算法流程如下。

2.1　归一化处理

对时间序列 $\{x_1,x_2,\ldots,x_n\}$ 使用公式（10）进行归一化处理：

$$c_i=\frac{1}{\delta\sqrt{2\pi}}\int_{-\infty}^{x_i}\mathrm{e}^{\frac{-(t-\mu)^2}{2\delta^2}}\mathrm{d}t \tag{10}$$

式中：c_i 为累积分布函数；μ 表示均值；δ^2 表示方差。

2.2　相空间重构

设置嵌入维数 m 和时间延迟 τ，对时间序列进行重构，重构后为

$$\boldsymbol{F}_j=\left[f_j,f_{j+\tau},\ldots,f_{j+(m-1)\tau}\right],1\ll j\ll N-(m-1)\tau \tag{11}$$

式中，$\boldsymbol{F}_j$ 表示 $j+(m-1)\tau$ 维向量空间中第 j 行，称为嵌入向量。

2.3 相空间符号化

设置均匀量化算子（Uniform Quantification Operator，UQO）如式（12）所示：

$$\mathrm{UQO}(u)=\begin{cases}0 & y_{\min}\le\mu<\Delta+y_{\min}\\ 1 & y_{\min}+\Delta\le\mu<2\Delta+y_{\min}\\ \cdots & \cdots\\ L-1 & y_{\max}-\Delta<\mu\le y_{\max}\end{cases}\tag{12}$$

式中：$y_{\max}$ 和 $y_{\min}$ 代表序列 Y_j 中的最大值和最小值；L 是离散化参数；Δ 表示离散间隔，且 $\Delta=(y_{\max}-y_{\min})/L$。将相空间 Y_j 的第一列 $Y(1)$ 符号化，得到符号相空间的第一列 $S(:,1)$。

2.4 计算符号化结果

相空间 Y 第 k 列 $Y(:,k)$，$2\ll k\ll m$，通过式子（13）可以得到符号化结果 $\mathrm{S}(i,k)$：

$$S(i,k)=S(i,1)+\left\lfloor Y(i,k)-\frac{Y(i,1)}{\Delta}\right\rfloor,1\le i\le N-(m-1)\tau\tag{13}$$

式中，式子 $\lfloor\ \rfloor$ 表示向下取整。

2.5 计算熵值

将符号化相空间 S 中每一行定义为一种符号模式（Symbol Pattern，SP），命名为 $\pi_l,1\le l\le L^m$。统计符号相空间中每种 π_l 出现的概率 P_l，得概率分布 $P=\{P_1,P_2,\ldots,P_l\},1\le l\le L^m$。根据香农熵计算公式可以得出 IPE 的值：

$$\mathrm{IPE}(m,L)=-\sum_{l=1}^{L^m}p_l\ln(p_l)\tag{14}$$

3 多尺度熵算法

单尺度信息熵算法对复杂信号的分辨效果有限的问题，COSTA 提出了一种粗粒化技术[17]，可以将信号从不同尺度下进行分析，算法过程如下：

将时间序列 $\{x_1,x_2,\cdots x_n\}$ 按照式（15）将分解为一系列子序列：

$$m_k^s=\frac{1}{s}\sum_{i=(k-1)s+1}^{ks}x_k,1\le k\le n/s\tag{15}$$

式中，尺度因子 s 的取值必须是大于等于 1 的整数，其下的子序列可以表示为 m^s。再利用信息熵算法计算不同尺度下的熵值，可得到多尺度熵结果。

3.1 仿真信号分析

为了验证基于辛几何模态分解的降噪算法的性能，构造含噪仿真信号进行降噪分析，仿真信号的表达式如式子（16）所示：

$$\begin{cases}e=1.5\cos(20\pi t+0.8\sin(60\pi t))+0.4\sin(240\pi t)\\ y=e+n\end{cases}\tag{16}$$

式中：e 为不含噪的仿真信号；n 为 0.5 倍标准高斯白噪声。图 1（a）和图 1（b）分别为原信号和加噪信号时域图，为了验证 SGMD 分解后的降噪效果，使用能量阈值的方法对仿真信号进行分解。

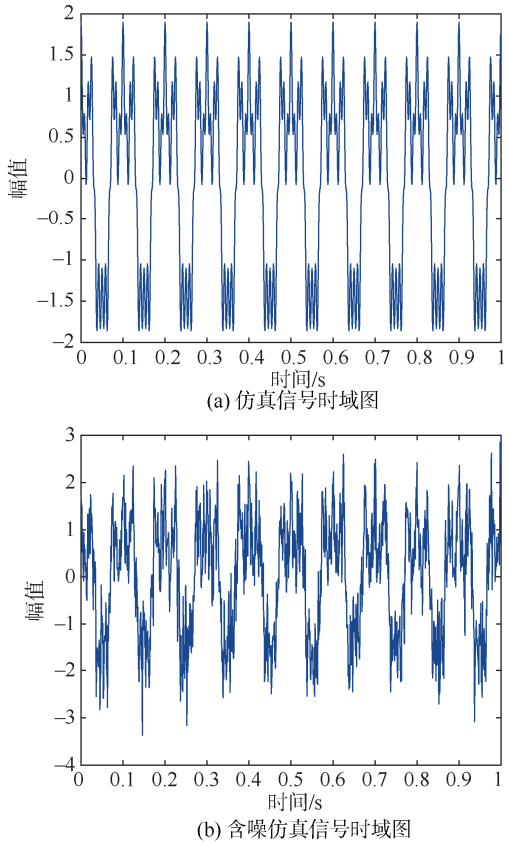

(a) 仿真信号时域图

(b) 含噪仿真信号时域图

图 1 仿真信号时域图

Fig. 1 Simulated signal time-domain waveform

为了测试和对比降噪的效果，通过 EMD、EEMD 及 VMD3 种分解方法降噪的结果进行对比。图 2 分别是 SGMD，EMD，EEMD 及 VMD 降噪的结果。

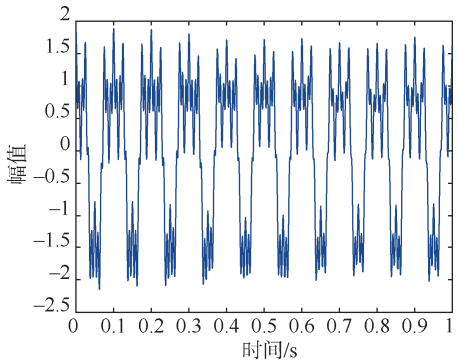

(a) SGMD降噪后的时域波形图

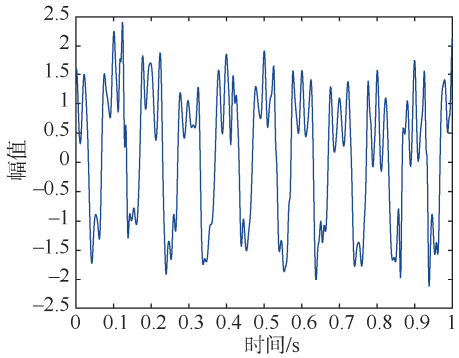

(b) EMD降噪后的时域波形图

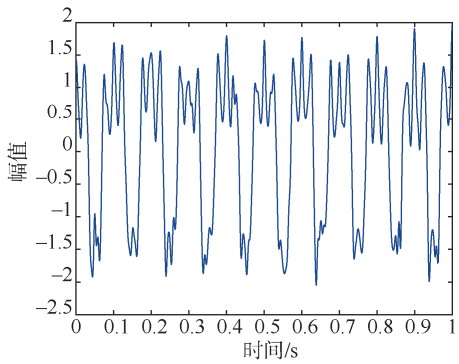

(c) EEDM降噪后的时域波形图

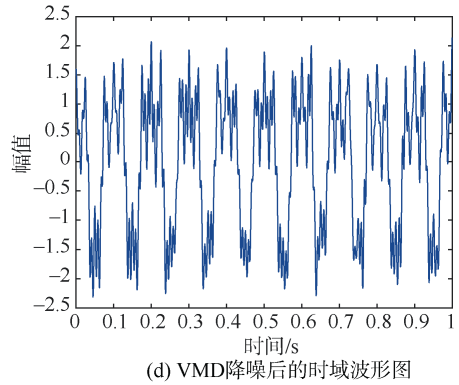

(d) VMD降噪后的时域波形图

图 2　4 种模态分解方法降噪结果

Fig. 2　Denoising results of 4 modal decomposition methods

从降噪前后的时域波形来看，SGMD 和 VMD 降噪的结果与原仿真信号更为接近。信噪比（SNR）和均方根误差（RMSE）可以量化算法的降噪效果。其中，信噪比越高降噪效果越好，反之越差；而均方根误差越小，降噪的效果越好，反之越差。表 1 是 4 种降噪方法的 SNR 和 RMSE，经过 SGMD 降噪后的 SNR 为 17.398 8，高于其他 3 种方法，而 RMSE 为 0.1481，明显低于其他方法，证明所提算法降噪效果优于其他 3 种方法。

表 1　不同模态分解方法的 SNR 和 RMSE

Table 1　SNR and RMSE of different modal decomposition methods

参数	降噪方法			
	EMD	EEMD	VMD	SGMD
SNR/dB	8.632 5	10.245 5	13.651 9	**17.398 8**
RMSE	0.406 3	0.337 5	0.228 0	**0.148 1**

3.2　舰船辐射信号降噪

本文使用的实测舰船数据来源于公开的 ShipsEar 数据集[16]，通过基于辛几何模态分解的降噪算法对 ShipsEar 数据集中的 3 种水面舰船进行分析，包括客船、大型货船和摩托艇。每种舰船辐射信号选取 2 000 点进行分析，分别为不同的舰船信号添加信噪比为 0 dB 的高斯白噪声，使用 SGMD 降噪算法对含噪舰船辐射噪声信号进行分析。

从图 3 降噪前后时域波形上看，客船、大船以及摩艇都存在明显噪声成分，在一些采样点上呈现密集毛刺，幅度波动比较大，会对信号分析结果产生较大的影响。而且 3 类舰船信号吸引子轨迹都较为混乱，在相空间中呈现发散性，轨迹点密度在中心区域比较稀疏。经过算法降噪之后，时域波形的周期性特征显著增强，吸引子轨迹比较规则而很光滑，相空间中明显呈现集中性，轨迹点密度在中心区域比较密集。通过对含 0 dB 噪声的 3 类不同舰船辐射噪声信号降噪处理结果分析，证明了本文提出的降噪方法可以在低信噪比下保留舰船辐射噪声动力学本质特征的同时具有良好的降噪效果。

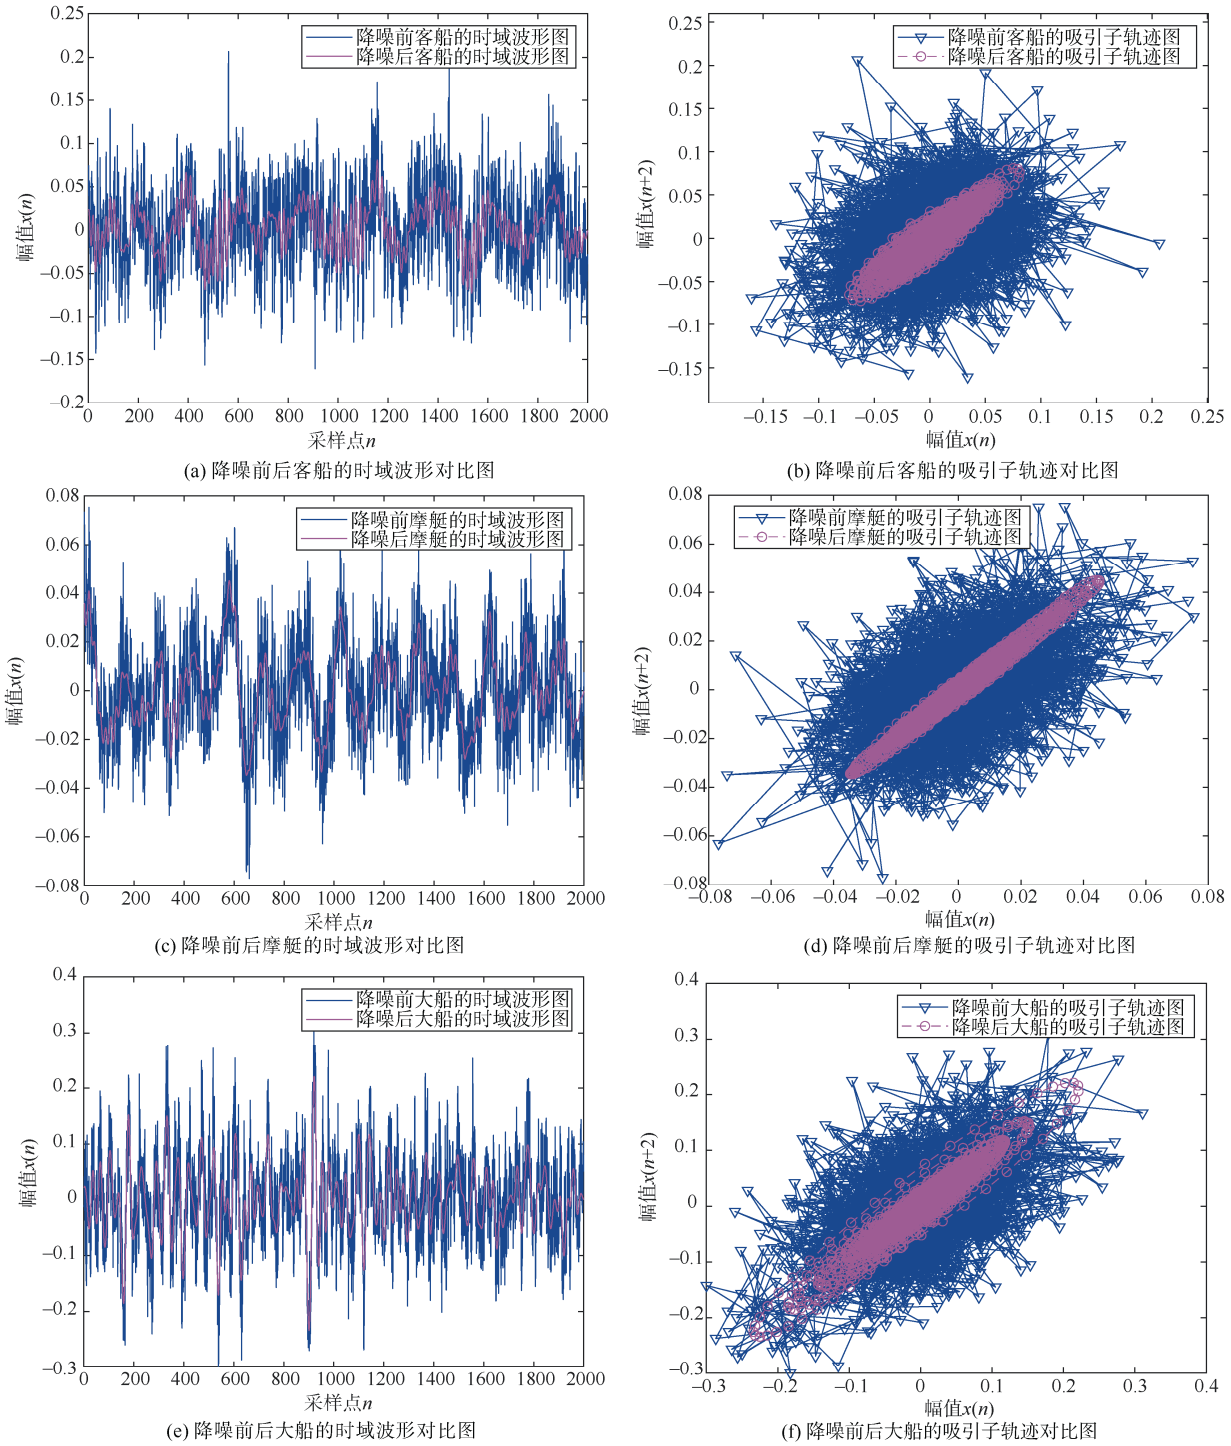

(a) 降噪前后客船的时域波形对比图　(b) 降噪前后客船的吸引子轨迹对比图

(c) 降噪前后摩艇的时域波形对比图　(d) 降噪前后摩艇的吸引子轨迹对比图

(e) 降噪前后大船的时域波形对比图　(f) 降噪前后大船的吸引子轨迹对比图

图 3　降噪前后舰船辐射噪声的时域波形和吸引子轨迹

Fig. 3　Time-domain waveforms and attractor trajectories of ship radiated noise before and after denoising

4　基于辛几何模态分解和改进排列熵的舰船辐射噪声特征提取

针对水声目标特征提取与识别过程中噪声难消除、稳健特征难提取问题，按照“信号降噪–特征提取–特征训练识别”的解决思路，提出一种基于辛几何模态分解和改进排列熵的舰船辐射噪声信号特征提取算法，首先利用 SGMD 对低信噪比舰船辐射噪声进行降噪，提取降噪信号的多尺度 IPE 算法特征，将得到特征输入到 PNN 进行分类

识别。其中，尺度设计为 1 至 20 。算法流程如图 4 所示。

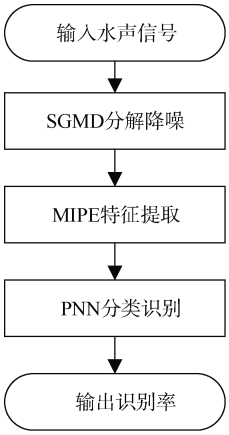

图 4　基于 SGMD 和 MIPE 的特征提取算法流程图

Fig. 4　Flowchart of feature-extraction algorithm based on SGMD and MIPE

本实验所选取数据来自 ShipsEar[18]数据集，其中客船、大船、摩艇各选取 3 只，一共 9 只舰船，每只舰船选 100 s 数据，每种类型信号 300 s 数据。分别添加 0 dB，5 dB 的高斯白噪声，得到不同信噪比下的 3 类舰船信号，利用所提的算法和排列熵算法对低信噪比的舰船辐射噪声信号进行特征提取，最后将提取到的特征输入到概率神经网络（PNN）[19]进行分类识别。PNN 分类时，将每个样本长度设为 1 s，每类选取 150 个样本作为测试集，150 个样本作为训练集。

图 5 为含 5 dB 噪声下 3 类舰船降噪前后的 MIPE 特征分析，从图 5（a）可以看到在尺度为 1~5 时，3 类舰船的特征在各尺度上存在一定的重叠。从图 5（b）降噪后的结果，可以看出特征分布在图中的不同区域，几乎没有重叠。

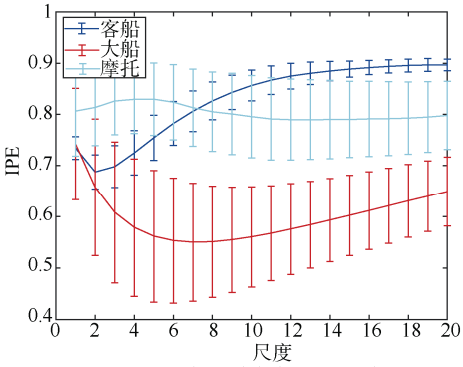

(a) 5 dB噪声下3类舰船的MIPE特征

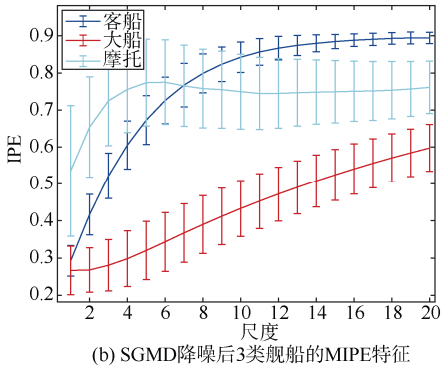

(b) SGMD降噪后3类舰船的MIPE特征

图 5　5 dB 噪声下 3 类舰船降噪前后的 MIPE 特征分析

Fig. 5　MIPE feature analysis of 3 ship types before and after denoising with 5 dB noise

为了进行对比，利用多尺度传统排列熵(MultiScale Permutation Entropy，MPE)算法对含噪信号进行特征提取分析。图 6 为含 5 dB 噪声下 3 类舰船的 MPE 特征，从熵值和曲线变化来看，3 类舰船在不同尺度上均存在重叠，难以从 MPE 特征上直接对舰船进行辨别。

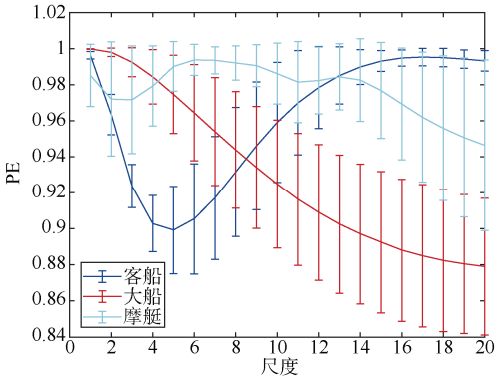

图 6　5 dB 噪声下 3 类舰船的 MPE 特征

Fig. 6　MPE features of 3 ship types with 5 dB noise

从表 2 特征分类的结果来看，含噪 5 dB 下 MPE 特征的识别率为 83.78%，对客船识别率仅为 74.67%。从表 3 来看，含 5 dB 噪声下 3 类舰船降噪前的识别率为 91.77%，明显高于 MPE；从表 4

表 2　5 dB 噪声下 3 类舰船的 MPE-PNN 分类结果

Table 2　Classification results of MPE-PNN for 3 ship types with 5 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	112	8	30	74.67
大船	0	142	8	94.67
摩艇	21	6	123	83.78
总计	-	-	-	83.78

表 3　5 dB 噪声下 3 类舰船的 MIPE-PNN 分类结果

Table 3　Classification results of MIPE-PNN for 3 ship types with 5 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	148	0	2	98.67
大船	0	125	25	83.33
摩艇	4	6	140	93.33
总计	-	-	-	91.77

表 4　5 dB 噪声下 3 类舰船的 SGMD-MIPE-PNN 分类结果

Table 4　Classification results of SGMD-MIPE-PNN for 3 ship types with 5 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	148	0	2	98.67
大船	0	150	0	100
摩艇	0	0	150	100
总计	-	-	-	99.56

来看，经过 SGMD 分解降噪之后识别率可以达到 99.56%，比未降噪提升了 7.79%，证明所提算法对低信噪比的舰船辐射噪声可以进行有效降噪和特征提取。

图 7 为 0 dB 噪声下 3 类舰船降噪前后的 MIPE 特征分析结果。在 0 dB 噪声下，客船与摩托艇的 MIPE 特征在不同尺度上存在一定程度的重叠；而经过 SGMD 降噪处理后，3 类舰船的 MIPE 特征分布呈现出更为清晰的区域划分，尤其在尺度 12~20 范围内，能够依据 MIPE 特征实现明显的类别区分；从表 5 和表 6 的分类结果来看，含 0 dB 噪声下 MIPE 特征识别率为 87.78%，经过 SGMD 分解降噪之后，特征识别率可以达到 96.89%，比未降噪提升了 9.11%。

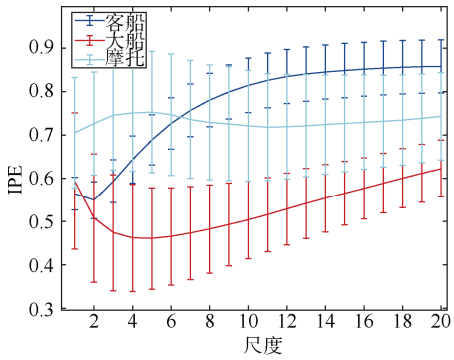

(a) 0 dB噪声下3类舰船的MIPE特征

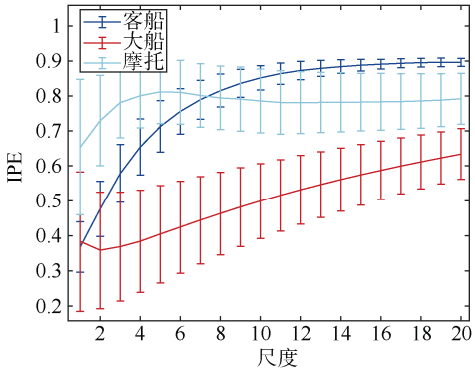

(b) SGMD降噪后3类舰船的MIPE特征

图 7　0 dB 噪声下 3 类舰船降噪前后的 MIPE 特征分析

Fig. 7　MIPE feature analysis of 3 ship types before and after denoising with 0 dB noise

图 8 为 0 dB 噪声下 3 类舰船的 MPE 特征，可以观察看到 3 类舰船的 MPE 特征在不同尺度上存在重叠，难以区分不同类型的舰船；从表 7 的 MPE-PNN 分类结果来看，含 0 dB 噪声条件下识别率仅为 77.56%。

以上实验结果表明：本文中所提算法在低信噪比条件下可以提取舰船辐射信号稳健特征，目标分类识别率高。

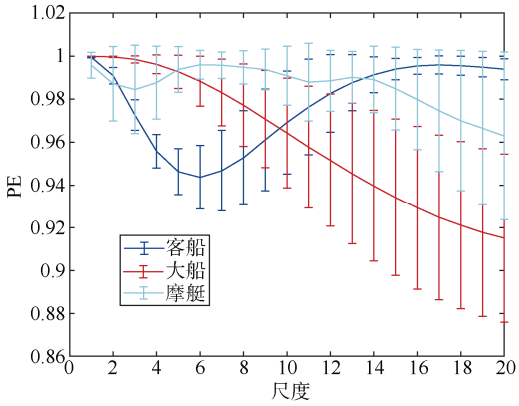

图 8　0 dB 噪声下 3 类舰船的 MPE 特征

表 5　0 dB 噪声下 3 类舰船的 MIPE-PNN 分类结果

Table 5　Classification results of MIPE-PNN for 3 ship types with 0 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	140	2	8	93.44
大船	1	116	31	77.33
摩艇	9	2	139	92.67
总计	-	-	-	87.78

表 6　0 dB 噪声下 3 类舰船的 SGMD-MIPE-PNN 分类结果
Table 6　Classification results of SGMD-MIPE-PNN for 3 ship types with 0 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	148	0	2	98.67
大船	0	140	10	93.33
摩艇	2	0	148	98.67
总计	-	-	-	96.89

表 7　0 dB 噪声下 3 类舰船的 MPE-PNN 分类结果
Table 7　Classification results of MPE-PNN for 3 ship types with 0 dB noise

类别	识别结果/个			识别率/%
	客船	大船	摩艇	
客船	99	12	39	66.00
大船	2	135	13	90.00
摩艇	26	9	115	76.67
总计	-	-	-	77.56

5　结束语

针对水声目标特征提取与识别过程中噪声难消除、稳健特征难提取问题，按照“信号降噪—特征提取—特征训练识别”的解决思路，提出一种基于 SGMD 和 MIPE 的舰船辐射噪声信号特征提取算法，首先利用 SGMD 对低信噪比舰船辐射噪声进行降噪，把降噪后的信号输入到 MIPE 中进行特征提取，将得到特征输入到 PNN 进行分类识别。实验结果表明：本文方法在信噪比为 5 dB 时，识别率达 99.56%，比降噪前提升了 7.79%；信噪比为 0 dB 时，识别率达 96.89%，比降噪前提升了 9.11%。算法在低信噪比的条件下可以对舰船辐射噪声进行准确辨别。

参考文献

[1] 曾晓光，金伟晨，赵羿羽，等. 海洋开发装备技术发展现状与未来趋势研判[J]. 舰船科学技术，2019，41（17）：1-7.

[2] 吴国溧. 基于海洋环境噪声的地声参数反演研究[D]. 长沙：国防科技大学，2020.

[3] JU Y，WEI Z X，LI H F，et al. A new low SNR underwater acoustic signal classification method based on intrinsic modal features maintaining dimensionality reduction[J]. Polish Maritime Research，2020，27（2）：187-198.

[4] BAYER F M，KOZAKEVICIUS A J，CINTRA R J. An iterative wavelet threshold for signal denoising[J]. Signal Process，2019，162：10-20.

[5] SEGER K D，AL-BADRAWI M H，MIKSIS-OLDS J L，et al. An empirical mode decomposition-based detection and classification approach for marine mammal vocal signals[J]. The Journal of the Acoustical Society of America，2018，144（6）：3181-3190.

[6] ZHANG Y A，YAN B B，AASMA M. A novel deep learning framework：prediction and analysis of financial time series using CEEMD and LSTM[J]. Expert Systems with Applications，2020，159：113609.

[7] CAO J，LI Z，LI J. Financial time series forecasting model based on CEEMDAN and LSTM[J]. Physica A：Statistical Mechanics and its Applications，2019，519：127-139.

[8] HUMPHREY W，DALKE A，SCHULTEN K. VMD：visual molecular dynamics[J]. Journal of Molecular Graphics，1996，14（1）：33-38.

[9] 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.

[10] LI H，LIU T，WU X，et al. An optimized VMD method and its applications in bearing fault diagnosis[J]. Measurement，2020，166：108185.

[11] XIE H B，GUO T R，SIVAKUMAR B，et al. Symplectic geometry spectrum analysis of nonlinear time series[J]. Proceedings of the Royal Society A：Mechanical，Physical and Engineering Science，2014，470：2170.

[12] PAN H Y，YANG Y，LI X，et al. Symplectic geometry mode decomposition and its application to rotating machinery compound fault diagnosis[J]. Mechanical Systems and Signal Processing，2019，114：189-211.

[13] 潘海洋. 基于辛几何模态分解和支持矩阵机的机械故障诊断方法[D]. 长沙：国防科技大学，2019.

[14] KUKAVICA I，ROBINSON J C. Distinguishing smooth functions by a finite number of point values，and a version of the Takens embedding theorem[J]. Physica D：Nonlinear Phenomena，2004，196（1-2）：45-66.

[15] BONIZZI P，KAREL J M，MESTE O，et al. Singular spectrum decomposition：a new method for time series decomposition[J]. Advances in Adaptive Data Analysis，2014，6（04）：1450011.

[16] CHEN Z，LI Y A，LIANG H T，et al. Improved permutation entropy for measuring complexity of time series under noisy condition[J]. Complexity，2019，10：1403829.

[17] COSTA M，GOLDBERGER A L，PENG C K. Multiscale entropy to distinguish physiologic and synthetic RR time series[C]// Computers in Cardiology. Memphis：IEEE，2002.

[18] SANTOS-DOMÍNGUEZ D，TORRES-GUIJARRO S，CARDENAL-LÓPEZ A，et al. ShipsEar：an underwater vessel noise database[J]. Applied Acoustics，2016，113：64-69.

[19] SPECHT D F. Probabilistic neural networks and the polynomial Adaline as complementary techniques for classification[J]. IEEE Transactions on Neural Networks，1990，1（1）：111-121.

（责任编辑：张曼莉）