

DOI:10.13382/j.jemi.B2508312

结合优化特征模态分解与谱熵特征的海面小目标检测*

毕雪雯¹ 行鸿彦^{1,2}

(1. 南京信息工程大学电子与信息工程学院 南京 210044; 2. 南通理工学院电气与能源工程学院 南通 226001)

摘要:针对海杂波背景下海面小目标检测中特征提取复杂、检测率低等问题,分析了海杂波与目标回波的数据特征,研究了特征模态分解(feature mode decomposition, FMD)在海杂波信号处理中的适用性,提出了一种结合优化特征模态分解与谱熵特征的海面小目标检测方法。使用结合互生生物搜索(symbiotic organism search, SOS)与粒子群优化(particle swarm optimization, PSO)的混合智能算法进行参数寻优,利用多尺度包络谱熵(multi-scale envelope spectrum entropy, MSESEn)提取信号特征,构建了虚警可控的深度极限学习机分类器模型(deep extreme learning machine, DELM)。将归一化之后的特征数据输入模型中,通过对比预测值与决策阈值的大小实时更新判决门限,实现了控制模型的虚警率,提高了算法的可靠性与检测效率。采用 IPIX 数据集进行验证,在 HV 极化方式下检测率平均提高了 18%,说明了所提方法性能优于傅里叶变换与三特征检测方法。

关键词:海杂波;目标检测;特征模态分解;多尺度包络谱熵;深度极限学习机

中图分类号: TN911.7

文献标识码: A

国家标准学科分类代码: 510.40

Sea-surface small target detection combining optimized feature mode decomposition and spectral entropy feature

Bi Xuewen¹ Xing Hongyan^{1,2}

(1. School of Electronics and Information Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China; 2. School of Electrical and Energy Engineering, Nantong Institute of Technology, Nantong 226001, China)

Abstract: Aiming at the problems of complex feature extraction and low detection rate in sea-surface small target detection under the background of sea clutter, the data characteristics of sea clutter and target echoes are analyzed, and the applicability of feature mode decomposition (FMD) in sea clutter signal processing is studied. Based on this, a sea-surface small target detection method combining optimized feature mode decomposition and spectral entropy features is proposed. A hybrid intelligent algorithm combining symbiotic organism search (SOS) and particle swarm optimization (PSO) was used for parameter optimization, and multi-scale envelope spectrum entropy (MSESEn) was used to extract signal features. A deep extreme learning machine (DELM) classifier model with controllable false alarm is constructed. The normalized feature data is input into the model, and the decision threshold is updated in real time by comparing the predicted value and the decision threshold. The false alarm rate of the control model is realized, and the reliability and detection efficiency of the algorithm are improved. The IPIX data set is used for verification, and the detection rate is improved by 18% on average under HV polarization mode, which shows that the performance of the proposed method is better than that of Fourier Transform and three-feature detection method.

Keywords: sea clutter; target detection; feature mode decomposition; multiscale envelope spectrum entropy; deep extreme learning machine

0 引言

海杂波是海洋雷达探测中常见的一种自然现象^[1],它是由海面波动产生的雷达回波。海杂波呈复杂的空间和时间变化特性,以及在不同海况和雷达观测条件下的非平稳性。由于海杂波的多维非高斯特性在高分辨率下表现得尤为明显^[2],且目标回波通常较弱、信杂比较低,使得海面小目标检测一直是研究者们面临的问题。

海杂波与小目标回波在统计和调制特性上存在显著差异:海杂波信号通常具有强烈的非高斯性、频谱扩展、瞬时频率剧烈波动等特征,能量分布较为分散,表现出高度随机性;而小目标回波信号则表现为频谱局部集中、能量分布稳定、调制特征明显^[3]。这种差异主要源于其物理产生机理的不同:海杂波主要由海面粗糙度引起的拉格朗日和白噪散射构成,受风浪、极化方式和入射角等影响大;目标回波则受限于其尺寸、形状和雷达散射截面,具有更为稳定和可建模的反射特性。这种差异为特征提取与目标检测提供了理论依据。

针对海杂波与目标回波难以有效区分的问题,国内外许多学者进行了大量研究。Fan 等^[4]使用经验模态分解(empirical mode decomposition, EMD)从复杂的海杂波信号中提取目标特征,并结合分形特征进一步提升弱目标的检测精度。EMD 通过自适应分解将信号分解为固有模态函数^[5](intrinsic mode functions, IMF),但在强噪声环境下容易产生模态混叠^[6]。Xu 等^[7]使用集合经验模态分解(ensemble empirical mode decomposition, EEMD)从海杂波信号中提取目标特征,并结合优化算法进行弱目标检测。EEMD 通过引入噪声辅助分解来解决传统 EMD 的模态混叠问题^[8],但其计算复杂度较高,影响实时性。Dai 等^[9]使用局部均值分解(local mean decomposition, LMD)提取无人机与鸟类的微多普勒特征,并结合补充特征提升目标分类性能。LMD 通过对信号进行局部均值和包络估计,具有良好的时频局部化能力,适用于非平稳信号分析。然而,LMD 在噪声干扰较强时分解精度易受影响,可能导致特征提取不稳定。Sun 等^[10]提出基于变分模态分解(variational mode decomposition, VMD)的分布式海杂波去噪算法,用于提高弱目标在海杂波背景下的检测性能。VMD 通过变分优化方式将信号分解为具有特定带宽的模态分量,具备良好的频率集中性和抗噪声能力^[11]。该方法在海杂波去噪中表现出较强的鲁棒性,但对模态数量的预设较为敏感,且计算复杂度相对较高。鉴于传统故障特征提取方法的局限性,Miao 等^[12]提出了特征模态分解(feature mode decomposition, FMD)。该方法借鉴反褶积的思想,以最大相关峭度准则为基础,构建自适应有限脉冲响应

(finite impulse response, FIR)滤波器,对信号进行迭代分解。FMD 能够同时兼顾信号的冲击性与周期性特征,在无需先验故障信息的前提下,表现出优异的抗干扰能力和分解稳定性^[13],为复杂环境下的特征提取提供了新思路。

由于海杂波与目标回波在熵值上表现不同,即不确定性大时熵值更高,因此信息熵可以作为特征提取的指标^[14]。目前常用的基于熵的特征有近似熵、样本熵、排列熵和散布熵^[15]等。这些熵值都被广泛应用于非线性的特征提取。但以上指标都是基于单一的时间尺度,导致其中包含的信息量较少。针对以上问题,本文结合样本熵、多尺度以及信号去噪过程中分解的模态分量的包络谱^[16]信息,提取信号的多尺度包络谱熵作为特征。

为提升复杂背景下海杂波目标检测的准确性与稳定性,本文提出一种结合优化特征模态分解与谱熵特征的海面小目标检测方法。该方法引入结合互生生物搜索(symbiotic organism search, SOS)与粒子群优化(particle swarm optimization, PSO)的混合智能算法,对关键参数进行自适应寻优。经过特征模态分解后,筛选出自相关性较好的模态分量组成重构信号。随后计算其多尺度包络谱熵(multi-scale envelope spectrum entropy, MSESEn),并将特征向量输入深度极限学习机(deep extreme learning machine, DELM)分类器,通过实时更新判决门限,实现控制模型的虚警率,用 IPIX 数据集验证所提方法的性能。

1 基本理论

1.1 FMD 算法

FMD 作为一种新的非递归信号分解方法,通过构建一组平滑的 FIR 滤波器并更新其系数,能够有效分离不同频率成分,避免模态混叠问题^[17]。在分解过程中,选择评价指标十分重要。

1) 输入原始信号数据集 x , 分解模态个数 n , 滤波器长度 L 。

2) 使用一个由 K 个汉宁窗初始化的 FIR 滤波器组, 每个滤波器对应不同带宽与中心频率, 设置从 $i = 1$ 开始迭代。

3) 对输入信号 x 进行滤波器组卷积, 得到第 k 个模态分量:

$$u_k^i = x * f_k^i \quad (1)$$

式中: $*$ 表示卷积运算; f_k^i 表示第 i 次迭代的第 k 个滤波器。

4) 当 u_k^i 的自相关谱过零点后达到局部最大值 R_k^i 时, 得到估计周期为 T_k^i 。使用原始信号 x 、模态分量 u_k^i 和估计周期 T_k^i 来更新滤波器系数, 完成一次迭代即设置 $i = i + 1$ 。

5) 判断迭代次数是否达到最大迭代次数。如果没有,则返回步骤 3); 否则,继续执行步骤 6)。

6) 计算每两个模式分量之间的相关系数 CC , 构造一个相关矩阵 $CC_{K \times K}$ 。保留 CC 值最大的两个模式, 并利用 T_k^i 计算其相关峭度, 随后保留两个模式中相关峭度较大的模式, 设置 $K = K - 1$ 。

7) 判断当前模式数 K 是否大于分解模式个数 n , 如果等于, 则停止迭代; 否则, 返回步骤 3) 继续合并冗余模式, 直到剩余模式个数为 n 。

然而传统的相关峭度主要用于检测周期性冲击信号, 海杂波的关键信息往往隐藏在调制包络中, 而非明显的脉冲模式。因此, 相关峭度依赖的周期滞后计算在海杂波信号处理中难以准确估计, 导致分解效果不稳定。相比之下, 包络谱熵 (envelope spectrum entropy, ESE) 衡量信号包络谱能量的有序性, 对调制特征更敏感, 能更有效区分目标回波与噪声。同时包络谱熵对能量分布的微小变化十分敏感, 更有助于保留弱目标特征。根据海杂波的特性, 选取包络谱熵作为评价指标可以衡量模式分量中包络谱能量的分布有序性, 有效识别调制特征突出的模式, 并抑制随机性高、无规律的模式, 流程如图 1 所示。

对每个模式分量 u_k 进行希尔伯特变换 (Hilbert transform, HT), 并获取包络:

$$e_k(n) = \sqrt{u_k(n)^2 + H(u_k(n))^2} \quad (2)$$

式中: $H(\cdot)$ 表示对信号进行希尔伯特变换。

利用快速傅里叶变换 (fast Fourier transform, FFT) 计算包络谱:

$$E_k(f) = |\text{FFT}(e_k(n))| \quad (3)$$

对包络谱进行归一化, 得到包络谱功率密度:

$$P_k(f) = \frac{E_k(f)^2}{\sum_f E_k(f)^2} \quad (4)$$

计算包络谱熵:

$$H_k = - \sum_f P_k(f) \log(P_k(f) + \varepsilon) \quad (5)$$

式中: H_k 表示第 k 个模式分量的包络谱熵; ε 表示防止数值溢出的微小常数。

综合比较相邻模式的 ESE 值与相关系数, 保留 ESE 值较低同时相关系数 > 0.3 的模式分量, 能够过滤噪声模式, 提高信号特征提取的稳定性和有效性。

1.2 多尺度包络谱熵

信息熵是衡量信息不确定性和信息量的指标。利用信息熵对希尔伯特包络谱提取包络谱熵^[18], 对信号从单一尺度扩展到多尺度, 可以有效避免所得熵值特征受到噪声的干扰。多尺度分析机制利用不同时间粒度对应的尺度因子 τ 计算熵值, 使谱熵能够同步捕获信号的局部瞬态特征与全局调制模式。在海杂波背景下的弱目标检

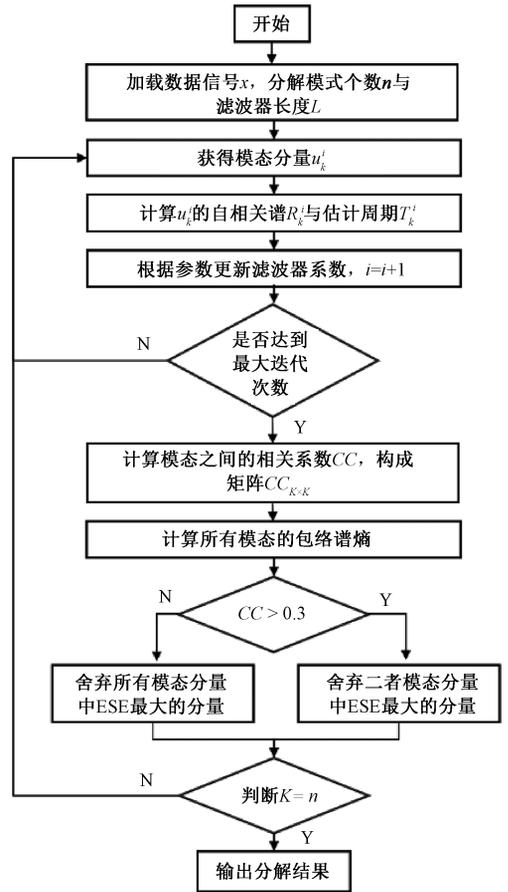


图 1 FMD 算法流程

Fig. 1 Flowchart of FMD algorithm

测场景中, 较小的 τ 能够增强对短时冲击的灵敏度, 较大的 τ 能够平滑噪声并突显目标周期性结构。这种跨尺度融合机制可以显著提升低信噪比环境下弱目标特征的可分离性与系统鲁棒性。

使用多尺度包络谱熵对海杂波的处理过程如下:

1) 对式 (3) 所得包络谱 $E_k(f)$, 限定频率范围 $f \in [f_{min}, f_{max}]$ 。实验中取 $f_{min} = 0.1 \text{ Hz}$, $f_{max} = 0.5 f_s$ (f_s 为采样率), 确保覆盖目标特征频带。

2) 将截取有效频段后的包络谱序列 $\{E_i\}_{i=1}^N$, ($i = 1, 2, \dots, N$) 分段得到新的序列:

$$\{E_j, E_{j+1}, \dots, E_{j+\tau}\}_{j=1}^T \quad j = 1, 2, \dots, T \quad (6)$$

式中: N 表示包络谱序列包含 N 个数数据点; τ 表示时间尺度; T 表示对 N/τ 向下取整, 即将原始包络谱序列划分成 T 段。

3) 构建连续粗粒化的序列 $\{w_j^{(T)}\}_{j=1}^T$:

$$w_j^{(T)} = \frac{1}{T} \sum_{i=(j-1)T+1}^j E_i, 1 \leq j \leq T \quad (7)$$

式中: $w_j^{(T)}$ 表示时间尺度 τ 下第 j 个点的值。

4) 对序列 $\{w_j^{(T)}\}_{j=1}^T$ 嵌入维数 m , 并构建成一个新

的序列 $\{w_i^{(\tau)}, w_{s+1}^{(\tau)}, \dots, w_{s+m}^{(\tau)}\}_{s=1}^{T-m+1}$, 得到满足 $d_{i,j}^{(\tau)} \leq \gamma$ 条件的元素概率:

$$C_i^{(\tau,m)}(\gamma) = \frac{n^{(\tau,m)}}{T-m+1} \quad (8)$$

式中: $d_{i,j}^{(\tau)}$ 表示所有不同向量元素 ($w_i^{(\tau)}, w_{i+1}^{(\tau)}, \dots, w_{i+m}^{(\tau)}$) 和 ($w_j^{(\tau)}, w_{j+1}^{(\tau)}, \dots, w_{j+m}^{(\tau)}$) 之间的距离, 且 $i \neq j, n^{(\tau,m)}$ 表示满足距离 $d_{i,j}^{(\tau)} \leq \gamma$ 的元素个数 (γ 为相似系数)。

5) 计算不同向量元素之间的相关度:

$$C^{(\tau,m)} = \frac{1}{T-m+1} \sum_{i=1}^{T-m+1} C_i^{(\tau,m)}(\gamma) \quad (9)$$

6) 以此类推, 增加维数至 $m+1$, 重复步骤 4~5), 计算新的相关度 $C^{(\tau,m+1)}$, 则定义多尺度 τ 下的样本熵集合为多尺度包络谱熵:

$$MSESEn(\tau, m) = SampEn(\tau, m, \gamma) = -\ln \frac{C^{(\tau,m+1)}}{C^{(\tau,m)}} \quad (10)$$

然而, 手动设置尺度因子 τ 与嵌入维数 m 存在主观性强、适应性差的问题, 难以保证谱熵特征在不同海况下的最优性。针对这一问题, 采用以最小化均方根误差 (root mean square error, RMSE) 为目标的准则, 结合 SOS-PSO 混合智能算法自适应确定最优多尺度参数组合, 从而确保谱熵特征提取的稳定性。

1.3 DELM 与虚警率控制

深度极限学习机是一种融合极限学习机 (extreme learning machine, ELM) 训练高效性与神经网络特征提取能力的模型结构^[19]。其核心思想是在传统 ELM 的基础上, 堆叠多个 ELM 自编码器 (ELM autoencoder, ELM-AE), 从而构建具备层次化特征表达能力的深度结构, 同时避免传统深度网络所需的大量迭代与反向传播操作。在 DELM 中, ELM-AE 作为基本构件, 用于无监督地提取输入数据的潜在特征。每个 ELM-AE 层通过随机初始化输入权重 ω_i 与偏置 v_i , 对输入进行线性映射后再通过激活函数 $g(\cdot)$ 进行非线性变换, 得到隐藏层输出矩阵 H 。随后, 采用最小二乘法计算输出权重 β , 以最小化重建误差^[20]。DELM 的训练过程如图 2 所示。输出权重的计算公式如下:

$$\beta = \left(HH^T + \frac{1}{C} I \right)^{-1} H^T X \quad (11)$$

式中: C 为正则化系数; I 为单位阵; X 表示输入样本矩阵。每层提取出的重构特征作为下一层的输入, 依次堆叠构建多层网络, 从而逐步挖掘输入数据的深层次结构特征。

在完成多层特征提取后, DELM 通过输出层完成有监督学习任务。输出层仍采用 ELM 结构, 并使用提取到的深度特征作为输入, 结合样本标签 T , 求解最终的输出权重:

$$\hat{\beta} = H^+ T \quad (12)$$

式中: H^+ 为隐藏层输出矩阵的广义逆矩阵。

最后得到预测值:

$$\hat{y} = g(H\hat{\beta}) \quad (13)$$

由于模型前期采用多层无监督学习结构, 无需人工设定输入权重和阈值, 因此具备训练速度快和泛化能力强的优势。但各隐藏层节点数仍需优化确定, 采用 SOS-PSO 混合智能算法自适应优化节点数组合, 具体优化准则如下:

以验证集上的检测概率最大化作为适应度函数, 目标函数定义为:

$$Fitness = P_d(N) \quad (14)$$

式中: $N = N_1, N_2, \dots, N_L$ 表示各隐藏层节点数组合; P_d 表示对应节点数配置下的检测概率。

在雷达信号处理和目标检测中, 虚警率是一个关键指标。通过合理控制虚警率 $P_{fa}(\lambda)$, 可以提高系统的实时性和效率^[21]。

设定一个目标虚警率 $FAR_{desired}$, 通过查找最接近目标虚警率的阈值 θ 来进行调整:

$$\theta = \underset{\lambda}{\operatorname{argmin}} | P_{fa}(\lambda) - FAR_{desired} | \quad (15)$$

根据计算得到的最优阈值 θ , 对测试集进行最终分类。若 $\hat{y} < \theta$, 则判定为不包含目标回波, 属于 H_0 假设。若 $\hat{y} \geq \theta$, 则判定为包含目标回波, 属于 H_1 假设。通过更新阈值 θ , 可以有效控制 DELM 的虚警率, 从而实现对分类性能的精细控制。

2 结合优化特征模态分解与谱熵特征的海面小目标检测

2.1 优化算法

在 FMD 分解过程中, 滤波器的带宽、中心频率等关键参数的选取直接影响分解效果。然而, 传统 FMD 依赖手动设定参数, 容易导致分解结果不稳定, 且不同信号环境下参数难以通用, 影响特征提取的鲁棒性。为解决该问题, 结合传统的粒子群优化算法与共生生物搜索算法, 引入 SOS-PSO 算法优化关键参数。

1) 粒子群优化算法

粒子群优化是一种群智能优化算法, 通过粒子间的信息交互, 寻找问题的最优解。首先在搜索空间中初始化一组粒子, 并用位置向量 x_i 表示。同时, 每个粒子具备一个速度向量 v_i , 用于调整自身在搜索空间中的移动方向与步长。在 PSO 算法的迭代过程中, 每个粒子都会记录自身的历史最优位置 P_{best_i} , 以及整个种群当前的全局最优位置 G_{best} 。

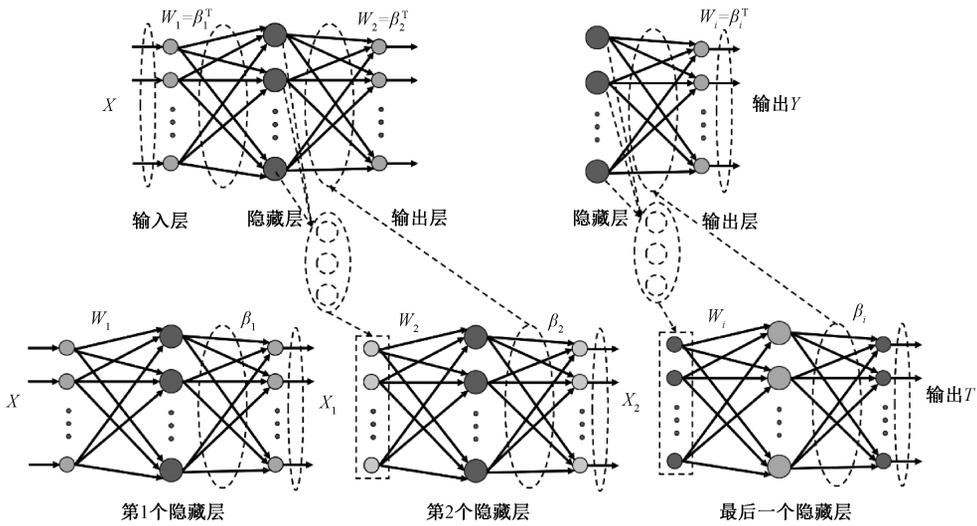


图 2 DELM 网络结构

Fig. 2 Network structure of DELM

为了平衡 PSO 的全局搜索与局部搜索,提高收敛速度和优化性能,传统惯性权值采用线性递减策略。但其存在局部最优收敛和搜索能力固化的问题。为解决此问题,引入 Logistic 混沌映射优化惯性权值。Logistic 混沌映射是一种非线性动态系统,能够生成具有随机性的混沌序列,可以避免过早收敛,提高算法性能和全局最优解质量。设置迭代次数为 n ,则 Logistic 映射的表达式如下:

$$d_{n+1} = \mu d_n (1 - d_n) \quad (16)$$

式中: d 表示混沌映射生成的随机数,且 $d \in (0,1)$; μ 表示 Logistic 映射控制参数,参考文献[22]可知,当 $\mu \in (3.57, 4)$ 时,系统处于混沌状态,本文优化算法选取 $\mu = 4$,即系统处于完全混沌状态。更新粒子的速度和位置:

$$\mathbf{v}_{i,n+1} = d_n \mathbf{v}_{i,n} + c_1 r_1 (\mathbf{P}_{\text{best}_{i,n}} - \mathbf{x}_{i,n}) + c_2 r_2 (\mathbf{G}_{\text{best}_n} - \mathbf{x}_{i,n}) \quad (17)$$

$$\mathbf{x}_{i,n+1} = \mathbf{x}_{i,n} + \mathbf{v}_{i,n} \quad (18)$$

式中: c_1 和 c_2 分别表示认知学习因子和社会学习因子; r_1 和 r_2 表示在区间 $[0,1]$ 均匀分布的随机数。

2) 共生生物搜索算法

PSO 算法在全局搜索能力和收敛速度方面可以优化 FMD 的参数选择过程,但是仍可能陷入局部最优,且对参数依赖较强,难以保证种群多样性。为了克服这些缺点,提出用共生生物搜索算法改进 PSO。SOS 通过模拟生态系统中生物个体的交互行为,使种群在进化过程中能更充分地探索解空间。与 PSO 不同,SOS 无需额外参数调整,且具备更好的自适应性,能够在全局搜索与局部搜索之间取得更好的平衡^[23]。结合 SOS 与 PSO 算法,可以增强粒子群的搜索能力,有效避免早熟收敛,提高算法的全局优化性能。SOS 的主要机制包括互利共生阶段、

偏利共生阶段和寄生阶段。

(1) 互利共生阶段

在此阶段,不同生物个体之间可以通过互利共生提高适应性。从初始种群中随机选择两个个体 \mathbf{x}_i 和 \mathbf{x}_j 进行相互学习,增强彼此的生存能力,更新后的位置表示为:

$$\mathbf{x}_{i,\text{new}} = \mathbf{x}_i + \text{rand}(0,1) \cdot (\mathbf{x}_{\text{best}} - \mathbf{M}_e B_1) \quad (19)$$

$$\mathbf{x}_{j,\text{new}} = \mathbf{x}_j + \text{rand}(0,1) \cdot (\mathbf{x}_{\text{best}} - \mathbf{M}_e B_2) \quad (20)$$

$$\mathbf{M}_e = \frac{\mathbf{x}_i + \mathbf{x}_j}{2} \quad (21)$$

式中: $\text{rand}(0,1)$ 表示 0~1 之间均匀分布的随机数; \mathbf{M}_e 表示生物个体 \mathbf{x}_i 和 \mathbf{x}_j 之间互相作用的关系; \mathbf{x}_{best} 表示当前种群的最优个体; B_1 和 B_2 为获益因子,表示生物个体通过互惠关系获得效益的能力,通常取 1 或 2。

(2) 偏利共生阶段

在此阶段,生物个体 \mathbf{x}_i 能够从其他生物个体 \mathbf{x}_j 身上获益,而不会影响对方,并借助最优个体 \mathbf{x}_{best} 进行学习。

$$\mathbf{x}_{i,\text{new}} = \mathbf{x}_i + \text{rand}(-1,1) \cdot (\mathbf{x}_{\text{best}} - \mathbf{x}_j) \quad (22)$$

(3) 寄生阶段

在此阶段,随机选择一个个体 \mathbf{x}_i 作为宿主,寄生生物侵入宿主并生成一个寄生体 \mathbf{x}_v 。若 \mathbf{x}_v 的适应度优于某个个体 \mathbf{x}_j ,则 \mathbf{x}_j 被替换;否则, \mathbf{x}_j 具有免疫性,被保留下来。该阶段增加了种群的随机性,可以避免陷入局部最优。

$$\mathbf{x}_v = \mathbf{x}_i \quad (23)$$

$$\mathbf{x}_v(p) = \text{rand}(1, \text{length}(p)) \cdot (\text{ub}(p) - \text{lb}(p)) + \text{lb}(p) \quad (24)$$

式中: p 表示变异体; ub 和 lb 分别表示搜索上界和搜索下界。

3) SOS-PSO 算法

提出的 SOS-PSO 优化算法,利用 SOS 算法优化 PSO 关键参数范围,使 PSO 算法在后续的寻优中可以根据搜索过程动态调整参数范围,并改进 PSO 算法在 FMD 分解中的参数设置,以提升信号分解的稳定性与特征提取能力。

(1) 初始化 SOS 算法和 PSO 算法的参数范围。

(2) 利用 SOS 算法随机生成初始参数,调用 PSO 算法,计算不同参数组合下的适应度函数值,选出当前最优个体 \mathbf{x}_{best} 。

(3) 通过互利共生阶段、偏利共生阶段和寄生阶段的过程,向更好的适应度进化。判断是否满足终止条件。

如果满足,则输出 PSO 算法的最优参数组合;否则,继续迭代,直到满足终止条件。

2.2 SOS-PSO-FMD 算法

针对海杂波背景下微弱目标信号难以辨识的问题,为了更好地区分海杂波与目标回波,提高其检测概率,本文采用 FMD 方法分解信号并提取特征。首先对海杂波信号进行预处理,为避免在 FMD 分解过程中手动选取参数可能造成的误差,利用 SOS-PSO 算法获取最优参数组合,并同步优化多尺度包络谱熵计算所需参数。随后提取模态分量的谱熵特征,输入虚警可控的深度极限学习机分类器,实现在复杂海杂波环境下对目标回波与杂波的有效识别与分类,流程如图 3 所示。

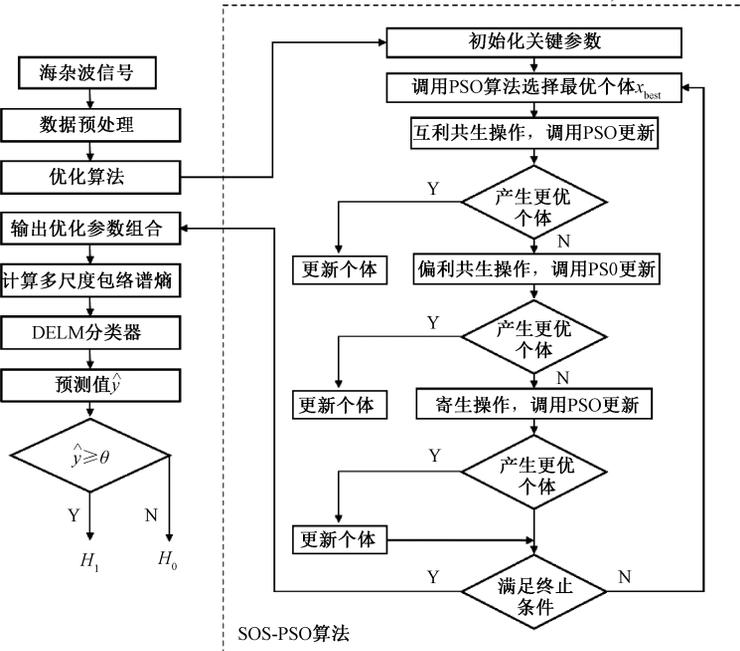


图 3 SOS-PSO-FMD 算法流程

Fig. 3 Flowchart of SOS-PSO-FMD algorithm

对海杂波与目标回波进行归一化预处理,将得到的数据集作为待分解的信号。训练时,获取待检测信号后将检测问题归为二元假设检验,并对海杂波信号与目标回波信号分别打上“0”标签与“1”标签。表达式如下:

$$\begin{cases} H_0: z = c, z_k = c_k; \\ H_1: z = s + c, z_k = c_k; \end{cases} \quad (25)$$

式中: c 表示海杂波信号; s 表示目标回波信号; H_0 假设表示回波信号中仅有海杂波信号; H_1 假设表示回波信号中含有目标回波。

输入计算多尺度包络谱熵所需的参数,嵌入维数 m 和时间尺度范围 $\tau \in [\tau_{\min}, \tau_{\max}]$ 。输入 DELM 分类器所需的参数,各隐藏层节点数 N 。初始化 SOS-PSO 算法的参数。设置 m 的范围为 $[1, 6]$, τ 的范围为 $[10, 30]$, N 的范围为 $[12, 24]$ 。

在 SOS 算法过程中,每个个体对应一组 FMD 初始参数 (n, L) ,经过种群在互利共生、偏利共生与寄生 3 个阶段的进化迭代,实现对参数组合的筛选。PSO 算法以最优参数组合为基础,在动态调整惯性权重与学习因子的机制下持续优化。在 SOS-PSO 优化过程中,以最小包络谱熵作为适应度函数,适应度值越小表示特征能量越集中、信号分解效果越好,算法以最优适应度不再显著变化作为停止准则。

将优化后的最优参数组合 (n, L) 输入 FMD,并对信号进行分解,得到模态分量。综合比较相邻模态的包络谱熵值与相关系数,保留熵值较低且相关系数 > 0.3 的分量,能够有效过滤噪声模态,提升信号特征提取的稳定性与有效性。

对筛选出来的模态分量进行希尔伯特变换,利用快

速傅里叶变换获得包络谱,将包络谱序列根据最优时间尺度 τ 分成 T 段。对分段后的时间序列进行连续粗粒化,并使用最佳嵌入维数 m ,得到一个新的序列 $\{w_s^{(\tau)}, w_{s+1}^{(\tau)}, \dots, w_{s+m}^{(\tau)}\}_{s=1}^{T-m+1}$ 。根据样本熵中相关度的定义,计算新的序列中不同向量元素之间的相关度,将多个时间尺度下的样本熵集合作为多尺度包络谱熵。

将归一化后的熵值输入虚警可控的 DELM 分类器。设定一个目标虚警率,并通过查找最接近目标虚警率的判决门限来进行调整。将待测数据训练后得到的预测值 \hat{y} 与判决门限 θ 进行比较。若 $\hat{y} < \theta$,则判定为不包含目标回波,属于 H_0 假设;若 $\hat{y} \geq \theta$,则判定为包含目标回波,属于 H_1 假设。此方法可以实时更新判决门限,从而实现分类器的虚警可控,并且提高检测率。

所提出的 SOS-PSO-FMD 算法融合智能优化与多指标信号解析策略,显著提升检测鲁棒性。其核心在于通过全局-局部协同优化实现分解参数与谱熵特征的自适应匹配;基于优化分解增强目标-杂波多尺度差异表征;结合虚警约束动态阈值机制协同调控检测性能,形成闭环控制。该设计预期在复杂海杂波中实现高精度低虚警检测。该算法的复杂度分析如表 1 所示。

表 1 复杂度分析

Table 1 Complexity analysis

算法模块	时间复杂度	关键参数说明
SOS-PSO 优化	$O(T(KLN + M(N/\tau)^2))$	T :迭代次数 K, L, M, τ :优化参数
FMD 信号分解	$O(KLN)$	K :模态数
模态筛选	$O(K^2N)$	L :滤波器长度 K :初始模态数
MSESEn 特征提取	$O(M(N/\tau)^2)$	M :尺度因子数
DELM 检测判决	$O(L^3 + LN_s)$	L :隐藏层节点总数 N_s :样本数
虚警控制	$O(N_s)$	需遍历样本预测值

3 实验结果与分析

使用的数据来源于 1993 年在加拿大东海岸采集的 IPIX 雷达目标数据库。该雷达工作在 x 波段,工作频率为 9.39 GHz,分辨率为 30 m。待检测目标为用金属丝网包裹的小球,直径约为 1 m。数据包含 4 种极化方式,每种极化方式由 14 个距离单元组成,每个距离单元包含 217(131.072 s)个脉冲。IPIX 雷达数据具体情况如表 2 所示。

3.1 SOS-PSO-FMD 算法性能评价

为验证提出的混合优化算法的性能优势,选取 FMD 参数组合与 MSESEn 参数组合作为对比对象。图 4(a)和(b)分别为上述两类参数优化过程中,采用的 4 种优化算法,即标准粒子群优化、基于遗传算法改进的粒子群

优化算法(genetic algorithm-particle swarm optimization, GA-PSO)、蚁群优化算法(ant colony optimization, ACO)以及提出的 SOS-PSO 算法,所对应的适应度收敛曲线。从图 4 可以看出,4 种算法在两类参数优化任务中的收敛趋势表现出较为一致的特征。PSO 在初期具备一定的下降速度,但易陷入局部最优,后期收敛速度趋缓;GA-PSO 通过引入遗传变异与交叉机制,在一定程度上提升了搜索性能,但整体收敛精度仍存在不足;ACO 算法在连续参数空间中的优化能力受限,表现出较大的震荡与波动,稳定性较差。相比之下,SOS-PSO 算法在两个参数优化任务中均表现出快速收敛与全局最优能力。特别是对于 FMD 参数组合的优化任务,SOS-PSO 算法在第 13 次迭代时即达到最优适应度值,后续保持稳定收敛趋势,显著优于其他 3 种对比算法。

表 2 IPIX 雷达数据说明

Table 2 Description of IPIX radar data

数据编号	数据名称	风速/ ($\text{km}\cdot\text{h}^{-1}$)	浪高/ m	角度/ ($^\circ$)	目标单元	受影响单元
1	#17	9	2.2	9	9	8,10,11
2	#26	9	1.1	97	7	6,8
3	#30	19	0.9	98	7	6,8
4	#31	19	0.9	98	7	6,8,9
5	#40	9	1.0	88	7	5,6,8
6	#54	20	0.7	8	8	7,9,10
7	#280	10	1.6	130	8	7,9,10
8	#310	33	0.9	30	7	6,8,9
9	#311	33	0.9	40	7	6,8,9
10	#320	28	0.9	30	7	6,8,9

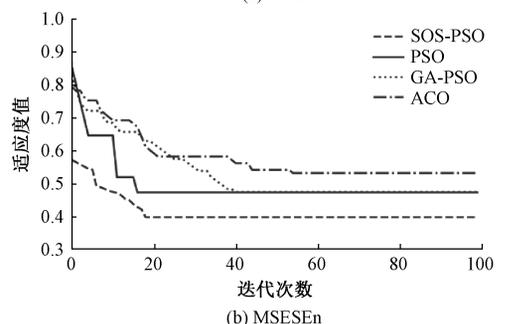
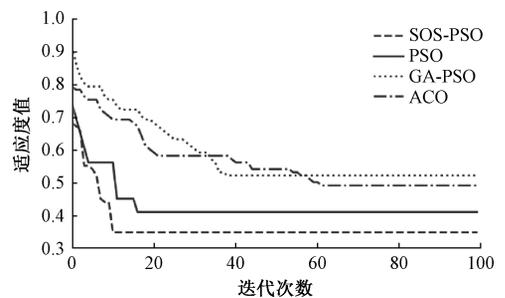


图 4 优化算法收敛曲线

Fig. 4 Convergence curve of optimization algorithm

为进一步验证优化算法在海杂波背景下对 FMD 性能的提升效果,将 FMD 分解模态个数设置为 $n = 10$,滤波

器长度设置为 $L = 80$ 。选取信噪比较低的#26 组海情数据进行实验,图 5 所示为优化后的 FMD 时域图。

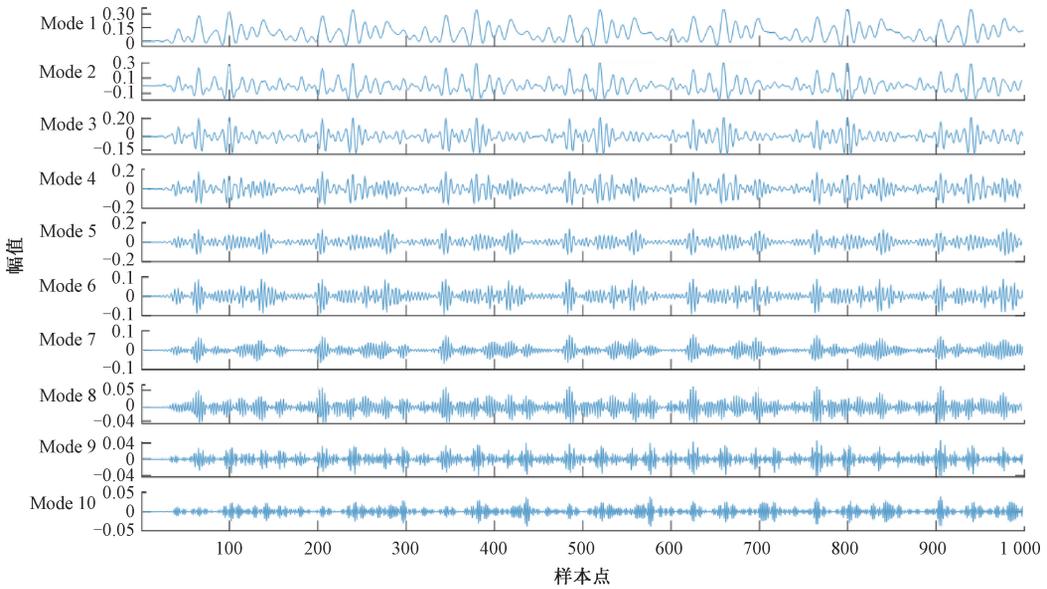


图 5 FMD 时域图

Fig. 5 Time domain diagram of FMD

接着对分解得到的 10 个模态分量进行筛选处理。结合包络谱熵与相关系数双指标进行评价,保留特征能量丰富且与原始信号具有较强相关性的模态。如表 3 所示,Mode 2、Mode 3 和 Mode 4 的相关系数均 > 0.3 ,同时包络谱熵均处于较低水平。将筛选出的有效模态分量进行叠加,合并成为一个代表性模态分量,用作后续特征提取的输入信号。为进一步验证所选模态的稳定性与代表性,选取 3 个筛选出的模态分量以及 3 个相关系数最小的模态分量,得到的自相关函数图如图 6 所示。由图 6 可见,被保留模态在非零点处有较大波动,呈现出良好的信号结构性特征;相比之下,其余模态在延迟下迅速衰减,具有噪声特征。

表 3 模态筛选指标

Table 3 Indicators for mode selection

模态分量	相关系数	包络谱熵
Mode 1	0.156 6	0.616 8
Mode 2	0.376 8	0.627 3
Mode 3	0.598 5	0.348 2
Mode 4	0.345 3	0.382 6
Mode 5	0.009 3	0.585 0
Mode 6	0.152 7	0.732 1
Mode 7	-0.054 6	0.790 6
Mode 8	-0.024 6	0.665 2
Mode 9	-0.017 1	0.781 9
Mode 10	-0.005 1	0.734 4

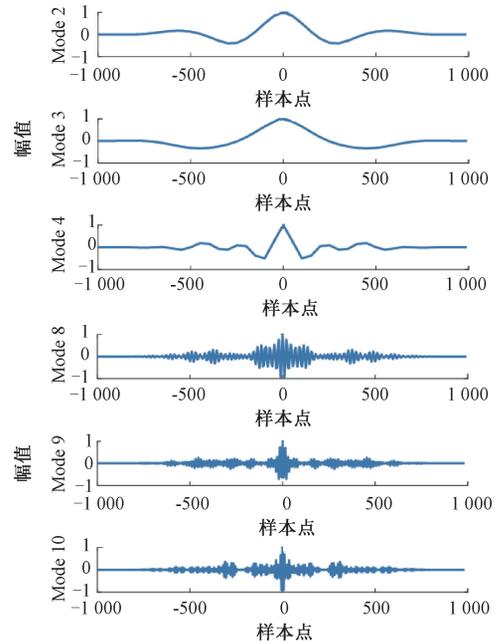


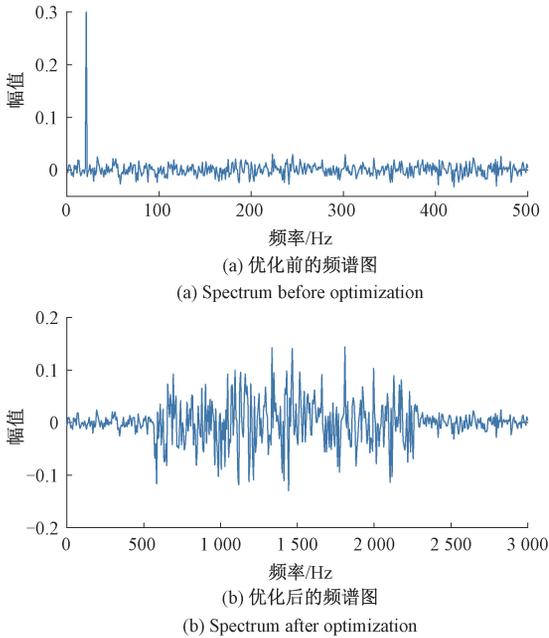
图 6 自相关函数图

Fig. 6 Autocorrelation function diagram

性,绘制模态分量在优化前后的频谱图,如图 7 所示。其中,图 7(a) 为默认参数下分解得到的频谱,可以看出曲线较为平坦,仅在低频边缘处出现小幅起伏,说明分量中主要包含噪声信息。而图 7(b) 中,能量在 500~2 300 Hz 频段呈现明显突起,具有清晰主频结构,表明该分量有效

为验证优化参数组合的有效性以及模态筛选的合理

保留了原始信号中的有效信息。



(a) 优化前的频谱图
(a) Spectrum before optimization
(b) 优化后的频谱图
(b) Spectrum after optimization

图 7 FMD 频谱图

Fig. 7 Spectrum diagram of FMD

3.2 特征可分性与可视化

为了验证在此方法下,目标回波与海杂波的特征可分性,具体选取 HH 极化下#54 数据的第 1 距离单元(海杂波)和第 8 距离单元(目标回波)作为实验数据。观测时间设置为 1.024 s,即每组数据包含 1 024 个样本点,两个距离单元分别被分为 128 组。在计算信号的多尺度包络谱熵时,为了进一步优化这一过程,采用 SOS-PSO 算法对嵌入维数和时间尺度因子进行参数优化,以 MSESEn 的均方根误差为适应度函数,进行最小化求解。根据经验,通常嵌入维数 m 的范围为 [1, 6],时间尺度 τ 的范围为 [10, 30]。若 m 过小,可能无法准确表征特征的复杂性;若 m 过大,可能引入噪声,从而导致过拟合问题。实验发现,当 $m = 3$ 时, RMSE 在整体搜索空间内取得最低值,表明此时熵序列能够更好地平衡信号复杂性与计算效率。因此,将 $m = 3$ 固定为最优嵌入维数,用于后续所有 MSESEn 特征计算。

随后,将熵值的 RMSE 作为衡量标准,不同时间尺度因子 τ 下的 RMSE 曲线如图 8 所示。图 8 中,当 $\tau = 24$ 时, RMSE 取得最小值 0.002 7。这表明此时 MSESEn 与原始信号之间的误差最小,此时的区分效果更加准确且可靠。

为了分析该时间尺度设置下的可分性表现,选取参数 $m = 3$,并分别在时间尺度 $\tau = 17, 24, 30$ 时下进行分析。其中, $\tau = 17$ 时 RMSE 取最大值,此时该时间尺度下误差最大; $\tau = 24$ 对应 RMSE 最小值,为最优时间尺度; $\tau = 30$

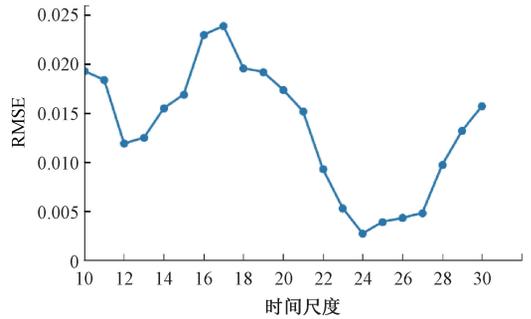


图 8 不同时间尺度下的均方根误差

Fig. 8 RMSE at different time scale

为所选时间尺度范围的最大值。计算出两个距离单元共 256 组数据的 MSESEn 之后,统计不同尺度因子下的熵值总数,如图 9 所示。从图中可以看出, $\tau = 24$ 时,目标回波与海杂波的分离效果最好,此时两个距离单元的重叠最小。

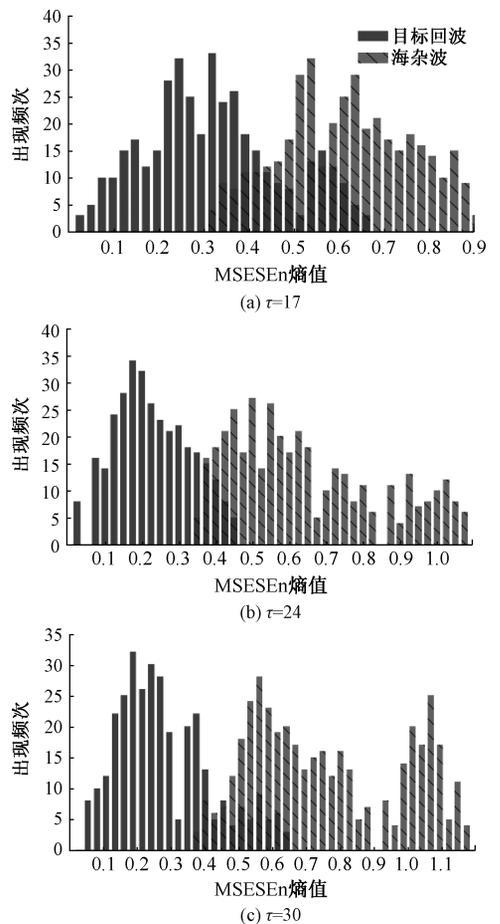


图 9 不同尺度因子的直方图对比

Fig. 9 Histogram comparison of different scale factors

为进一步定量评估,引入概率分布重叠率指标进行对比分析。将两类样本的 MSESEn 值统计成归一化直方

分布后,计算其重叠区域面积。实验结果表明,当 $\tau = 24$ 时,目标与杂波的重叠率仅为 17.5%;而在 $\tau = 17$ 和 $\tau = 30$ 时,重叠率分别为 42.3%和 28.8%。结合图 8 和 9 可知, $m = 3$ 和 $\tau = 24$ 时的联合参数组合能够最大化 MSESEn 特征的稳定性与类别可分性,验证了 SOS-PSO 优化策略在多尺度参数选择方面的有效性与合理性。

3.3 检测性能分析

为了验证所提算法的检测性能,使用表 2 中 4 种极化方式下的 10 组数据进行蒙特卡罗实验。参考文献 [24] 对于海杂波数据的平均信杂比的分析,可知交叉极化比主极化具有更高的平均信杂比,在目标检测中表现出更优的效果。这是因为交叉极化方式能够更有效地抑制海杂波,从而提高信杂比和检测率。并且在数据#54、#311、#320 中,这一特性尤为明显。同时,VV 极化比 HH 极化产生更大的布拉格散射,导致 VV 极化的平均信杂比更低。

考虑到 DELM 分类器的结构参数会对检测效果产生重要影响,经过优化算法确定了在当前数据条件下的最优参数组合,如表 4 所示。

表 4 DELM 的最优参数组合

Table 4 Optimal parameter combination of DELM

关键参数	参数取值
输入层维度	8
输出层维度	1
隐藏层节点数	[22, 14]
激活函数	sigmoid

由于观测时长与尺度因子会对检测概率造成影响,因此分别对不同的观测时长与尺度因子在固定虚警率下进行对比。SOS-PSO-FMD 在观测时长分别为 0.512 s ($N=512$)、1.024 s ($N=1\ 024$)、2.048 s ($N=2\ 048$)、4.096 s ($N=4\ 096$) 下,尺度因子为 $\tau=[17,24]$ 下,虚警率 $P_{fa}=10^{-3}$ 时的平均检测概率图。由图 10 (a) 可知 SOS-PSO-FMD 对#54、#311 和 #320 数据的检测效果明显更好。从图 10(b) 和 (c) 可以看出,随着观测时间的延长,检测器的性能在 4 种极化下几乎都有显著提升。但是图 10 (d) 也可以看出,观测时间过长会导致效果提升趋缓,算法复杂度上升。

为定量分析以上结论,表 5 为不同观测时长下各极化方式对应的平均检测概率。由表 5 可知,随着观测时间的增加,检测器的平均检测率分别提升了 6.18%、1.88%、0.425%。可以看出,当观测时间从 2.048 s 增加到 4.096 s 时,检测概率提升幅度已非常有限,HH 极化仅提升 1.81%,HV 极化甚至略有下降。这表明,过长的观测时间在提升检测性能上效果递减,甚至可能因系统计算负担加重而引入不稳定性。因此,在兼顾检测性能

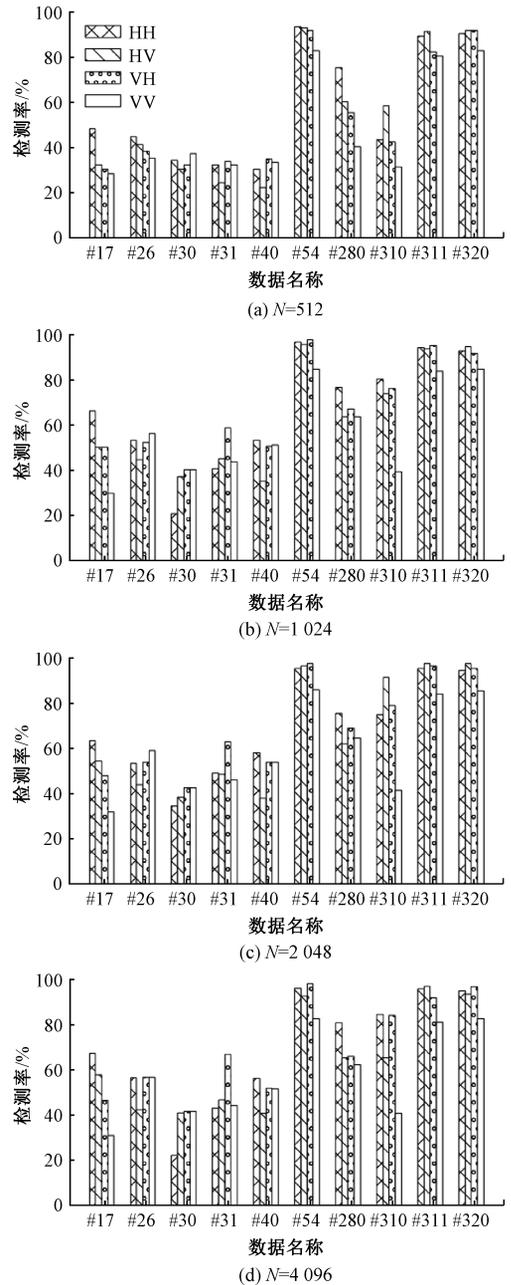


图 10 不同观测时间下的检测性能

Fig. 10 Detection performance under different observation durations

和实时性要求的前提下,观测时间不宜超过 2.048 s。

表 5 不同观测时间下的平均检测概率

Table 5 Average detection probability under different observation durations

观测时间/s	HH	HV	VH	VV
0.512	0.796	0.839	0.829	0.742
1.024	0.865	0.897	0.882	0.809
2.048	0.881	0.917	0.906	0.824
4.096	0.899	0.902	0.915	0.829

在明确了观测时长对检测性能的影响后,接着在固定观测时间为 2.048 s,虚警率 $P_{fa} = 10^{-3}$ 时,分析不同时间尺度因子对检测性能的影响。设置 τ 为 10~30,4 种极化方式下的平均检测概率如图 11 所示。结果表明,随着时间尺度的增加,4 种极化方式的平均检测率均呈现快速上升后缓慢下降的趋势。这是因为时间尺度增大时,包络谱熵的计算将得到包含较多细微变化的序列,使得信号的复杂度升高。但是尺度过大会导致信号细节被平滑处理,造成熵值无法充分反映信号中的所有复杂特征。

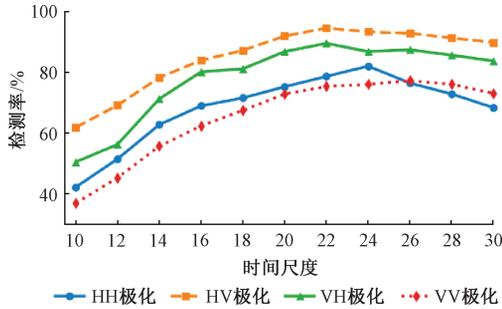


图 11 不同时间尺度下的检测性能

Fig. 11 Detection performance under different scale factors

为进一步验证所提算法在时间尺度适应性上的优势,引入 RCMDE-XGBoost 方法^[24]与多尺度样本熵方法进行对比。选取#54 数据,保持观测时间为 2.048 s,虚警率为 $P_{fa} = 10^{-3}$ 的设置进行实验。4 种方法在#54 数据的 4 种极化方式下的平均检测率对比如图 12 所示。结果表明,4 种方法的检测率均随时间尺度呈现先升后降趋势,但 SOS-PSO-FMD 在全尺度范围内始终保持最优性能,在 $\tau = 24$ 时达到峰值 91.24%,较时频三特征检测器和 RCMDE-XGBoost 方法分别提升 12.5% 和 19.1%。

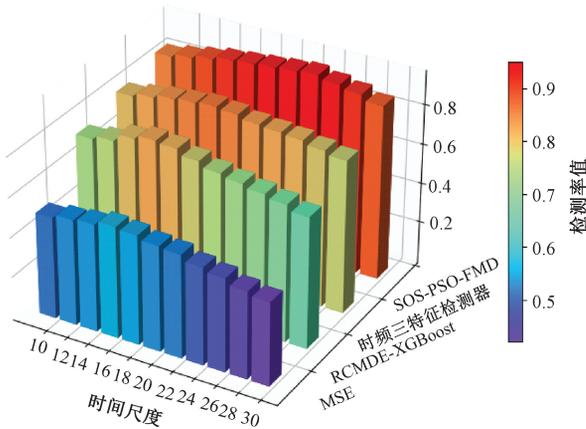
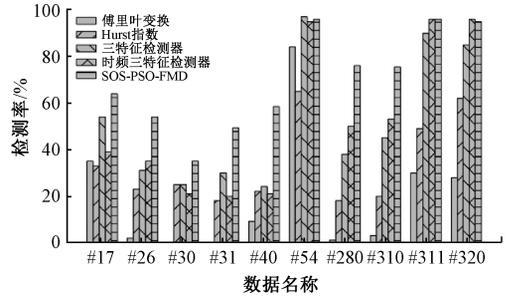


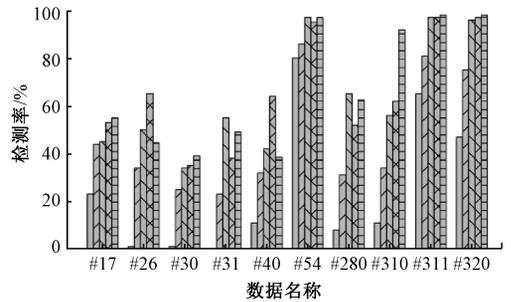
图 12 不同时间尺度下 4 种检测方法的检测性能

Fig. 12 Detection performance of four methods under different scale factors

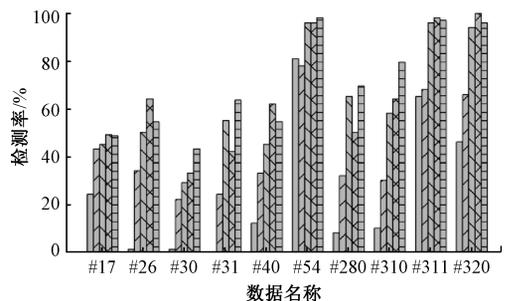
度适应性后,进一步扩展对比范围,将 SOS-PSO-FMD 与其他检测方法进行对比。5 种检测方法分别在 4 种极化下的检测性能结果如图 13 所示。其他 4 种检测方法分别是傅里叶变换、Hurst 指数^[25]、三特征检测器^[26]和时频三特征检测器^[27]。其中,嵌入维数 $m = 3$,观测时间为 1.024 s,虚警率 $P_{fa} = 10^{-3}$,尺度因子 $\tau = [17, 24]$ 。由图 13 可见,在 HH、HV、VH、VV 极化下 5 种检测器的平均检测概率分别为 20.53%、43.53%、70.75%、84.25%、



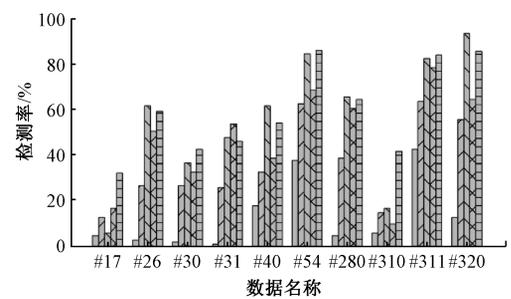
(a) HH



(b) HV



(c) VH



(d) VV

图 13 4 种极化下 5 种检测方法的检测性能

Fig. 13 Detection performance of five methods under four polarization modes

在明确时间尺度对检测性能的影响及所提方法的尺

86.35%, 可以知道 SOS-PSO-FMD 检测器明显优于其他检测方法。虽然在 HV 和 VH 极化下, 对 #17、#26、#40 数据组的检测率略低于时频三特征检测器, 但是整体检测效果仍然较好。这主要是因为所提检测器通过结合多尺度、时域及频域的熵特征, 可以有效区分海杂波与目标回波, 同时配合 DELM 分类器自适应调节决策门限, 进一步提高检测性能, 整体表现远优于其他 4 种方法。

观测时间对于检测性能也有很大的影响, 表 6 为观测时间分别为 0.512 和 1.024 s 两种情况下, 不同检测器在 10 组数据下的平均检测概率。从表 6 可以得出以下 3 个结论。1) 适当延长观测时间可以提高目标检测的概

率。这是因为在合理的时间范围内, 随着观测时间的延长, 信杂比提升, 同时噪声影响降低, 使得检测器在复杂海杂波环境下的适应性和鲁棒性更强。2) 当观测时间从 1.024 s 缩短至 0.512 s 时, 前 3 种检测器的性能损失分别为 32.29%、8.47% 和 10.09%, 而 SOS-PSO-FMD 检测器的性能损失为 6.69%。这表明所提检测器能够在不同尺度上捕捉信号的全局与局部特征, 使得在较短观测时间内也能够提取到目标的特征差异。3) 在不同的观测时间下, 基于 SOS-PSO-FMD 检测器都可以获得最高的平均检测概率。这是因为所提检测器能够有效提取目标与海杂波的差异特征, 使其在短时间内也能获得较高检测概率。

表 6 不同观测时间下的平均检测概率

Table 6 Average detection probability

检测器	观测时间/s	HH	HV	VH	VV
Hurst 指数检测器	0.512	0.223	0.404	0.448	0.241
	1.024	0.301	0.536	0.576	0.328
三特征检测器	0.512	0.577	0.736	0.776	0.569
	1.024	0.622	0.797	0.813	0.598
时频三特征检测器	0.512	0.717	0.826	0.812	0.706
	1.024	0.821	0.882	0.878	0.789
SOS-PSO-FMD 检测器	0.512	0.796	0.839	0.829	0.742
	1.024	0.865	0.897	0.882	0.809

4 结 论

本文提出一种结合优化特征模态分解与谱熵特征的海面小目标检测方法。针对时域的特征参数容易受到噪声影响的缺点, 将时域与频域结合, 通过特征模态分解提取信号中的模态分量。利用融合互生生物搜索与粒子群优化的混合智能算法, 以最小包络谱熵为目标函数, 自适应优化 FMD 过程中的关键参数, 提升去噪能力。随后提取优化分解后各模态的多尺度包络谱熵特征, 并将其输入深度极限学习机进行分类。通过对比预测值与决策阈值的大小实时更新判决门限, 达到控制虚警率恒定的目的。实验结果表明, 所提算法具有良好的检测性能, 适用于海面小目标的检测。

参考文献

[1] DAS N, HOSSAIN M S. Investigation of the impact of sea conditions on the sea surface reflectivity in maritime radar sea clutter modeling [C]. Proceedings of the 2023 International Conference on Electrical, Computer and Communication Engineering. IEEE, 2023:1-4.

[2] YANG B, JIANG M, WANG J M, et al. Analysis of extendibility of sea clutter model in high sea states based on measured data [C]. Proceedings of the 2022 3rd

International Conference on Computer Vision, Image and Deep Learning & International Conference on Computer Engineering and Applications. IEEE, 2022:140-143.

[3] HE H, LI Z, ZHANG X, et al. Characteristic description and statistical model-based method for sea clutter modeling [J]. Remote Sensing, 2024, 16(23):4429.

[4] FAN Y, WANG X, GONG Y, et al. Weak target detection within sea clutter based on EMD fractal feature [C]. 2023 XXXVth General Assembly and Scientific Symposium of the International Union of Radio Science. IEEE, 2023:1-4.

[5] YIN Y J, LIU Y D, FAN Y Q, et al. Research on vegetable commodity price prediction with improved LSTM based on EMD decomposition and iCHOA optimization [C]. Proceedings of the 2023 5th International Conference on Machine Learning, Big Data and Business Intelligence. IEEE, 2023:153-157.

[6] TAN J D, YANG C, ZHANG T X, et al. Detection of underwater ferromagnetic objects by EMD decomposition based on industrial frequency electromagnetic fields [C]. Proceedings of the 2023 2nd International Conference on Artificial Intelligence and Computer Information Technology. IEEE, 2023:1-5.

[7] XU C, WANG Z, ZHANG G. Clutter suppression and weak target detection using EEMD-WOA algorithm for

- FMCW radar [C]. 2023 3rd International Conference on Communication Technology and Information Technology. IEEE, 2023:30-33.
- [8] LI B, WANG F, ZHAO W, et al. Electricity price prediction model based on EEMD-KPCA-LSTM [C]. Proceedings of the 2024 4th International Conference on Electronic Materials and Information Engineering. IEEE, 2024:120-127.
- [9] DAI T, XU S, TIAN B, et al. Extraction of micro-doppler feature using LMD algorithm combined supplement feature for UAVs and birds classification[J]. Remote Sensing, 2022, 14(9):2196.
- [10] SUN J, XING H Y, WU J J, et al. Distributed sea clutter denoising algorithm based on variational mode decomposition [J]. Instrumentation, 2020, 7 (3): 23-32.
- [11] XU R, GAO L. Improved DBO optimization VMD wavelet threshold vibration signal denoising method[C]. Proceedings of the 2024 IEEE 6th Advanced Information Management, Communicates, Electronic and Automation Control Conference. IEEE, 2024:1194-1200.
- [12] MIAO Y, ZHANG B, LI C, et al. Feature mode decomposition; New decomposition theory for rotating machinery fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2022, 70(2):1949-1960.
- [13] ZHANG N, ZHAO L, ZHANG X, et al. Bearing fault diagnosis based on SDWPSO-FMD [C]. Proceedings of the 2024 IEEE 22nd International Conference on Industrial Informatics. IEEE, 2024:1-6.
- [14] JOSHI R, RANADE M, PATVARDHAN N, et al. Information entropy and audit quality; Exploring the role of information theory in enhancing audit quality [C]. Proceedings of the 2024 15th International Conference on Computing Communication and Networking Technologies. IEEE, 2024:1-5.
- [15] ZHANG H, HE S S. Analysis and comparison of permutation entropy, approximate entropy and sample entropy [C]. Proceedings of the 2018 International Symposium on Computer, Consumer and Control. IEEE, 2018:209-212.
- [16] CHEN D X, LI J J, LIN R D, et al. Information entropy and optimal scale combination in multi-scale covering decision systems [J]. IEEE Access, 2020, 8: 182908-182917.
- [17] ZOU J, ZHAO L, MI B, et al. Fault diagnosis based on feature mode decomposition of whale optimization algorithm[C]. Proceedings of the 2023 Prognostics and Health Management Conference. IEEE, 2023:232-237.
- [18] 陈培演, 孙晓, 欧立涛, 等. 基于 Hilbert 包络谱熵和 GA-SVM 的水轮发电机轴承故障诊断[J]. 机电工程技术, 2024, 53(3):199-204.
- CHEN P Y, SUN X, OU L T, et al. Bearing fault diagnosis of hydrogenerator based on Hilbert envelope spectrum entropy and GA-SVM [J]. Mechanical and Electrical Engineering Technology, 2024, 53 (3): 199-204.
- [19] ZHANG S, NIU D, ZHOU Z, et al. Prediction method of direct normal irradiance for solar thermal power plants based on VMD-WOA-DELM [J]. IEEE Transactions on Applied Superconductivity, 2024, 34(8):1-4.
- [20] HU H, YANG M. Photovoltaic power load forecasting method based on DBO-DELM [C]. Proceedings of the 2024 9th International Conference on Intelligent Computing and Signal Processing. IEEE, 2024: 1582-1585.
- [21] 赵娟. 表面肌电信号的去噪及肌疲劳评价研究 [D]. 北京:中国地质大学, 2023.
- ZHAO J. The denoising of multi-channel SEMG and muscle fatigue evaluation research [D]. Beijing: China University of Geosciences, 2023.
- [22] 冯延鹏, 张爱华, 梁婷婷, 等. 基于改进 SSA 优化 SVM 的超窄间隙焊接质量评估 [J]. 电子测量与仪器学报, 2023, 37(6):195-205.
- FENG Y P, ZHANG AI H, LIANG T T, et al. Quality evaluation of ultra-narrow gap welding based on improved SSA optimized SVM [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37 (6): 195-205.
- [23] DASH S K, MISHRA S, RAUT U, et al. An improved symbiotic organisms search algorithm for multi-objective simultaneous optimal allocation of DSTATCOM and DG units [C]. Proceedings of the 2021 International Conference in Advances in Power, Signal, and Information Technology. IEEE, 2021:1-6.
- [24] 王海峰, 行鸿彦, 陈梦, 等. 基于精细复合多尺度散布熵与 XGBoost 的海面小目标检测方法 [J]. 电子测量与仪器学报, 2023, 37(1):12-20.
- WANG H F, XING H Y, CHEN M, et al. Sea-surface small target detection method based on refined composite multiscale dispersion entropy and XGBoost [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1):12-20.
- [25] SHUI P. Tri-feature-based detection of floating small targets in sea clutter [J]. IEEE Transactions on Aerospace and Electronic Systems, 2014, 50 (2): 1416-1430.

- [26] LI D C, SHUI P. Floating small target detection in sea clutter via normalised Hurst exponent [J]. *Electronics Letters*, 2014, 50(17):1240-1242.
- [27] SHI S N, SHUI P. Sea-surface floating small target detection by one-class classifier in time-frequency feature space[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, 56(11):6395-6411.

作者简介



毕雪雯, 2021 年于北京交通大学获得学士学位, 现为南京信息工程大学硕士研究生, 主要研究方向为微弱信号检测。

E-mail: bixuewen01@ 163.com

Bi Xuewen received her B. Sc. degree from Beijing Jiaotong University in 2021. Now

she is a M. Sc. candidate at Nanjing University of Information Science and Technology. Her main research interest includes

weak signal detection.



行鸿彦(通信作者), 1983 年于太原理工大学获得学士学位, 1990 年于吉林大学获得硕士学位, 2003 年于西安交通大学获得博士学位, 现为南京信息工程大学教授、博士生导师, 主要研究方向为气象仪器设计与计量、信号检测与处理等。

E-mail: xinghy@ nuist.edu.cn

Xing Hongyan (Corresponding author) received his B. Sc. degree from Taiyuan University of Technology in 1983, M. Sc. degree from Jilin University in 1990 and Ph. D. degree from Xi'an Jiaotong University in 2003. Now he is a professor and Ph. D. supervisor in Nanjing University of Information Science and Technology. His main research interests include design and metering of meteorological instruments and signal detection and processing, etc.