

DOI: 10.13382/j.jemi.B2508458

# 基于 IVMD-WPD-HHO-LSTM 的海杂波小目标检测方法\*

李梦杰<sup>1,2</sup> 行鸿彦<sup>1,2</sup> 吴涵<sup>1,2</sup>

(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:**为提高海杂波背景下微弱目标的检测性能,提出了一种基于改进变分模态分解(improved variational mode decomposition, IVMD)-小波包多阈值分解(wavelet packet multi-threshold decomposition, WPD)与哈里斯鹰优化算法(Harris Hawks optimization, HHO)优化长短期记忆网络(long short-term memory, LSTM)相结合的检测方法。采用改进变分模态分解-小波包多阈值分解去噪技术,通过自适应粒子群(adaptive particle swarm optimization, APSO)优化确定变分模态分解最优参数,精确分解海杂波信号为多个本征模态函数(intrinsic mode functions, IMF)。针对噪声较强的高频 IMF,设计多频段小波包分解与分层阈值去噪策略,有效抑制噪声并保留微弱目标特征。利用哈里斯鹰算法对长短期记忆网络模型的超参数进行优化,提升其在复杂海杂波背景下的非线性时序建模能力。通过相空间重构与去噪信号的结合,显著提高了目标检测的精度和抗干扰能力。实验使用加拿大 McMaster 大学 IPIX 雷达实测数据,结果表明,该方法在高信噪比和低信噪比环境下均显著提高了检测精度,相比传统长短期记忆网络方法,检测能力至少提高了 35%。

**关键词:**海杂波去噪;小波包分析;多阈值准则;HHO-LSTM;微弱目标检测

**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

## The sea clutter weak target detection method based on IVMD-WPD-HHO-LSTM

Li Mengjie<sup>1,2</sup> Xing Hongyan<sup>1,2</sup> Wu Han<sup>1,2</sup>

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

**Abstract:** To enhance the detection performance of weak targets against sea clutter, this paper proposes a hybrid detection method. This method integrates improved variational mode decomposition (IVMD) combined with wavelet packet multi-threshold decomposition (WPD), and a long short-term memory (LSTM) network optimized by the Harris Hawks optimization (HHO) algorithm. The IVMD, whose optimal parameters are determined adaptively by adaptive particle swarm optimization (APSO), is employed to precisely decompose the sea clutter signal into several intrinsic mode functions (IMFs). For the high-frequency IMFs containing strong noise, a multi-band wavelet packet decomposition and layered threshold denoising strategy is designed within the WPD framework to effectively suppress noise while preserving weak target characteristics. The Harris Hawks optimization algorithm is utilized to optimize the hyperparameters of the LSTM model, thereby enhancing its capability for nonlinear time-series modeling within the complex sea clutter environment. By combining phase space reconstruction with the denoised signals, the accuracy and anti-interference capability of target detection are significantly improved. Experiments using the real-world IPIX radar dataset from McMaster University, Canada, demonstrate that the proposed method markedly improves detection accuracy under both high and low signal-to-noise ratio conditions. Compared to traditional LSTM-based methods, the detection capability is improved by at least 35%.

**Keywords:** sea clutter denoising; adaptive wavelet packet; HHO-LSTM; weak target detection

## 0 引言

在目标检测领域,小目标由于其体积小、速度慢等特征,导致检测精度低、漏检率高,成为了研究中的重要问题。特别是在海面小目标检测中,除了目标本身的特性外,复杂的海面环境也对目标检测造成了极大挑战。如何克服海面复杂环境的影响,并提升检测精度,已经成为海雷达目标检测领域亟待解决的重要课题。

海杂波是雷达照射海面后返回的后向散射回波,其中包含目标与周围环境的复杂信息。因此,研究海杂波信号特性,特别是其混沌性和非线性特征,为海面小目标检测提供了新的思路。Haykin 等<sup>[1]</sup>利用冰区多参数成像 X 频段雷达获取的实际海杂波数据,揭示了其内在的混沌动力学特性。这一发现为理解海杂波的复杂性与建模奠定了重要基础,推动了基于混沌特性的海面目标检测研究<sup>[2]</sup>。然而,待检测目标的出现会干扰海杂波的混沌状态,造成非线性预测模型失准,预测误差随之增大。在此背景下,实现对海杂波的高精度建模及其中噪声的有效滤除,构成当前研究的关键环节。

针对海杂波背景下的微弱目标检测这一核心挑战,多种信号处理技术被应用于噪声抑制。传统方法如 Donoho<sup>[3]</sup>提出的小波阈值去噪(wavelet threshold denoising, WTD)通过多尺度分析实现信号增强,在处理平稳信号时效果显著。但其预设的固定阈值准则难以适应海杂波固有的强非平稳性与时变特性,导致去噪效果受限。近年来,自适应信号分解方法如经验模态分解(empirical mode decomposition, EMD)<sup>[4]</sup>与变分模态分解(variational mode decomposition, VMD)<sup>[5]</sup>展现出显著优势。其中,VMD 通过构建并求解变分优化问题,凭借其严格的数学约束条件(如带宽限制),可有效抑制模态混叠现象<sup>[6]</sup>,分解结果更具物理意义。但是,VMD 的分解性能高度依赖于预设参数模态数  $K$  与惩罚因子  $\alpha$  的恰当选取。文献<sup>[7]</sup>采用鲸鱼优化算法(whale optimization algorithm, WOA)进行参数优化,但其收敛速度与全局搜索能力仍有提升空间。

在去噪后的信号预测方面,长短期记忆网络(long short-term memory, LSTM)<sup>[8-9]</sup>因其优异的时序建模能力被广泛采用。相较于主要解决静态特征划分问题的传统支持向量机(support vector machine, SVM)<sup>[10]</sup>,LSTM 网络在建模海杂波非平稳时序信号的动态演变方面更具优势。Ma 等<sup>[11]</sup>首次将 LSTM 应用于海杂波幅度预测,但其研究未深入探讨超参数对模型性能的影响。苏宁远等<sup>[12]</sup>提出采用粒子群算法(particle swarm optimization, PSO)优化 LSTM 隐含层节点数,然而传统群智能算法易陷入局部最优。近期,优化长短期记忆网络或其变体(如

双向长短期记忆(bidirectional long short-term memory, BiLSTM))结合智能优化算法以提升海杂波建模与目标检测性能的研究日益增多<sup>[13]</sup>。Heidari 等<sup>[14]</sup>提出的哈里鹰优化算法(Harris Hawks optimization, HHO)通过模拟捕食行为的动态平衡策略,在参数优化中展现出更强的抗干扰能力,为 LSTM 超参数优化提供了新思路。

现有研究多侧重于单一去噪或预测模型的改进,缺乏对信号处理全链路的协同优化。文献<sup>[15]</sup>提出 WTD-奇异值分解(Singular Value Decomposition, SVD)-WOA-LSTM 联合检测框架,但小波与 SVD 的级联去噪可能导致高频信号失真。文献<sup>[6]</sup>采用 VMD 模糊熵去噪虽提升了噪声抑制能力,却未考虑高频模态中潜在的目标信息保留。针对上述局限,本文创新性地将参数优化 VMD 与自适应小波包阈值滤波相结合。首先通过 PSO 算法实现 VMD 参数自适应选择,克服了传统经验设定法的次优问题;其次设计小波包多阈值分层处理策略,利用频段重排技术与自相关分选准则,在抑制噪声的同时保留高频微弱目标特征;最后构建 HHO 优化的 LSTM 预测模型,通过非线性收敛因子与 Levy 飞行机制提升超参数搜索效率,实现检测阈值区间的显著扩展。

## 1 理论基础

### 1.1 VMD

在非平稳信号处理领域,VMD 提供了一种自适应分解机制,可将复杂信号解析为若干带宽受约束的本征模态。该方法与 EMD 的关键区别在于其求解过程,VMD 通过建立并求解变分优化问题,从原理上规避了 EMD 易产生的端点效应和模态混叠等缺陷。

VMD 的基本目标是将原始信号  $f(t)$  分解为  $k$  个模态分量  $u_k(t)$  (每个模态的频带有限),每个模态具有独特的频谱特性,且模态的频率逐步向零频移动。其数学模型通过最小化每个模态频谱的带宽,并要求重构信号近似原始信号,优化目标如下:

$$\begin{aligned} \min_{\{u_k\}, \{\omega_k\}} & \left\{ \sum_{k=1}^K \|\partial_t [u_k(t) e^{-j\omega_k t}] \|_2^2 \right\} \\ \text{s. t.} & \sum_{k=1}^K u_k(t) = f(t) \end{aligned} \quad (1)$$

式中:  $u_k(t)$  为第  $k$  个模态分量;  $\omega_k$  为其中心频率;  $f(t)$  为原始信号。该优化问题的目标是最小化所有模态的瞬时带宽,同时保持信号的完整性。

VMD 的效果在很大程度上依赖于两个关键参数,模态数  $k$  和惩罚因子  $\alpha$ 。其中,模态数  $k$  控制信号的分解精细度,惩罚因子  $\alpha$  控制频带的压缩程度。在实际应用中,这两个参数通常依赖于经验或通过优化算法手动

调整。

### 1.2 自适应粒子群优化算法 (APSO)

APSO 是在经典粒子群优化算法基础上发展而来的改进型群体智能优化算法<sup>[16]</sup>。引入了动态调节机制,能够根据搜索进程的变化自动调整控制参数(如惯性权重、学习因子等),从而增强算法在不同阶段的搜索能力,提高收敛速度与全局寻优性能。

在经典 PSO 中,粒子的速度和位置更新如下:

$$v_i^{(t+1)} = wv_i^t + c_1r_1(p_i - x_i^{(t)}) + c_2r_2(g - x_i^{(t)}) \quad (2)$$

$$x_i^{(t+1)} = x_i^{(t)} + v_i^{(t+1)} \quad (3)$$

式中:  $x_i^{(t)}$  和  $v_i^{(t)}$  第  $i$  个粒子在第  $t$  代的位置和速度;  $p_i$  为粒子的个体历史最优位置;  $g$  为全局最优位置;  $w$  为惯性权重,影响粒子的记忆能力;  $c_1, c_2$  为学习因子;  $r_1, r_2$  为  $[0, 1]$  的随机数,用于增强多样性。

与标准 PSO 不同,APSO 通过在线评估种群状态自动调节控制参数,主要包括如下机制。

惯性权重  $w$  控制粒子对历史速度的依赖程度。在 APSO 中,惯性权重根据迭代进度或群体的“拥挤程度”进行自适应调整,一般形式如下:

$$w^{(t)} = w_{\max} - \frac{(w_{\max} - w_{\min}) \cdot t}{T} \quad (4)$$

或基于群体多样性:

$$w = \begin{cases} w_{\max}, & \text{早期探索阶段} \\ w_{\min}, & \text{收敛阶段} \end{cases} \quad (5)$$

当算法陷入局部最优或种群收敛过快时,自适应调整个体学习因子  $c_1$  与社会学习因子  $c_2$  的大小,有助于在不同阶段间平衡“个体引导”与“群体协同”的关系。

灾变机制。为跳出局部最优,APSO 常引入灾变策略,在搜索陷入停滞时部分粒子重新初始化,以重新激活种群活力。

### 1.3 APSO-VMD 的参数优化

VMD 的性能高度依赖于模态数  $k$  和惩罚因子  $a$  的选取。传统方法通常依赖于经验性选择或启发式算法来确定这些参数,但这种方法在面对复杂信号时可能无法获得最优解,进而影响 VMD 的分解精度和抗干扰能力。为此,本文提出基于自适应粒子群优化的自适应参数优化机制,通过自动化搜索确定最优参数组合,显著提升分解精度与抗干扰能力,具体流程如图 1 所示。

为了量化不同参数组合下的分解效果,以最小化包络熵之和为目标的适应度函数。该准则能够通过降低模态分量的噪声干扰,增强特征信息的稀疏性。具体来说,适应度函数定义如下:

$$F(\theta) = \sum_{k=1}^K EE(\hat{u}_k) = \sum_{k=1}^K \left[ - \sum_{t=1}^N p(\hat{u}_k(t)) \ln p(\hat{u}_k(t)) \right] \quad (6)$$

式中:  $\hat{u}_k(t)$  是通过 VMD 分解得到的第  $k$  个模态分量;  $p(\hat{u}_k(t))$  是模态分量的概率密度函数,通常可以通过归一化处理得到;  $K$  是模态数;  $N$  是信号的长度。

APSO 算法通过不断更新粒子的位置和速度,逐步逼近全局最优解,最终获得适应度函数最小的 VMD 参数组合。

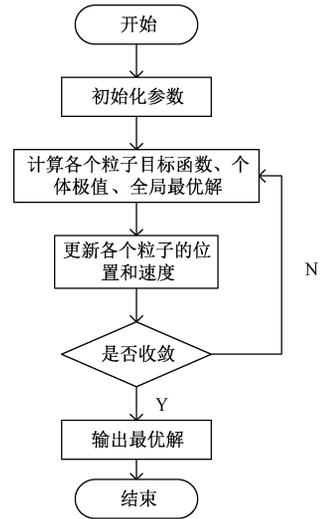


图 1 APSO-VMD 参数优化流程

Fig. 1 Parameter optimization flowchart of APSO-VMD

与传统的经验法或鲸鱼优化算法相比,APSO 在 VMD 参数优化中具有较强的全局搜索能力。经验法通常依赖于专家经验和手工调节参数,虽然简单但难以保证适应各种信号的需求。而 WOA 通过模拟鲸鱼捕食过程进行搜索,虽然具有一定的全局搜索能力,但在某些复杂问题中收敛速度较慢。APSO 则通过引入粒子间的协作与信息共享,能够在广泛的解空间中进行高效搜索,避免了陷入局部最优解的困境,从而实现更为精确的 VMD 参数优化。

### 1.4 小波包多阈值去噪

小波包分解是小波分析的扩展,能够对信号进行更细致的多频带分解,适用于复杂非平稳信号的去噪处理<sup>[17]</sup>。与传统的小波变换只分解低频部分不同,小波包能够同时细化信号的高频和低频部分,提供更丰富的频谱信息。小波包多阈值去噪方法结合了小波包分解与多阈值去噪技术,通过在不同频带上应用阈值处理,有效去除噪声并保留信号的主要特征。

小波包分解通过递归分解信号,将其划分为多个频带,每个频带由一组系数表示。在去噪过程中,常用的方法是对小波系数应用阈值处理。与传统方法仅对低频部分进行阈值处理不同,小波包多阈值去噪方法在所有频带上都施加阈值处理,以更全面地去除噪声。

设原始信号为  $f(t)$ , 小波包分解将其表示为:

$$f(t) = \sum_{k=1}^n \sum_{l=1}^m d_{k,l} \psi_{k,l}(t) \quad (7)$$

式中:  $\psi_{k,l}(t)$  是小波包基函数;  $d_{k,l}$  是对应的分量;  $k$  和  $l$  分别表示小波包树的层次和频带。

在信号去噪领域, 常用的 4 种阈值准则, 分别是 Rigrsure、Minimaxi、Sqtwolog、Heursure, 因其各自特性而具备不同的适用场景与去噪效果。Rigrsure 与 Minimaxi 准则更适用于信号的低频及中频成分处理, 其阈值设定策略相对保守, 能够在抑制噪声的同时有效保护有用信号成分不被过度滤除。相比之下, Sqtwolog 和 Heursure 准则主要针对高频区域, 虽能高效地实现噪声消除, 但也存在引发过度去噪进而损失部分有效信号成分的风险。

海杂波信号的频谱特性表现为低频部分含有重要目标信息, 中频部分具有较强的过渡性, 而高频部分则主要为噪声。因此, 在小波包分解后的去噪过程中, 需根据不同频段的特性选择合适的阈值准则。

Minimaxi 准则适用于含有目标信号关键信息的低频部分, 能够有效抑制噪声并保留信号细节, 达到理想的去噪效果。

Rigrsure 准则适用于包含噪声与目标信号交错的中频部分, 通过最小化误差来去除噪声, 同时保留信号的完整性。

Heursure 准则适用于高频部分, 其中噪声较强, 通过自适应阈值方法有效去除高频噪声, 同时避免过度滤波, 从而保护目标信号。

为应对非平稳、非线性海杂波信号的去噪难题, 本文采用改进变分模态分解 (IVMD) 技术获取其本征模态函数分量 (intrinsic mode function, IMF)。特别地, 将分解产生的高频 IMF 分量作为独立信号对象进行滤波处理。为进一步优化去噪效果, 本文采用基于 IMF 分量频率顺序的小波包多阈值联合处理方法, 其具体实施步骤如下。

1) IMF 信号特性分析与小波基函数选择。鉴于 IMF 分量呈现宽频带分布特性, 且高频分量内可能蕴含微弱目标信息, 优先选用正交性好且高频信息保留能力优异的小波基函数 db4。同时, 采用 Shannon 熵作为量化信号信息含量的标准度量。

2) 确定小波包分解层数  $N$ 。合理选择小波包分解的层数至关重要, 若层数过少, 噪声可能无法充分去除; 而若层数过多, 则可能导致计算量过大并增加去噪过度的风险。

3) 小波包分解与系数排序。首先对 IMF 信号进行小波包分解, 得到与树节点对应的分解系数。不同于传统方法按自然顺序直接进行阈值处理, 本文将小波包分解系数按频率从低到高进行排序, 从而确保频率与树节点号正确匹配。

4) 自相关函数计算与频段划分。通过对小波包分解系数进行排序后计算其自相关函数, 并结合信号和噪声的自相关特性, 能够有效实现对信号的频段划分。信号的自相关函数通常非零滞后点呈现波动性特征, 而噪声的自相关函数则在相同滞后点迅速衰减。基于这一显著差异, 可以精准地将信号划分为低频、中频与高频部分, 从而为信号的深入分析和分解提供可靠依据。

5) 确定阈值准则。根据频段的不同, 选用相应的阈值准则。低频部分采用 Minimaxi 准则, 中频部分采用 Rigrsure 准则, 高频部分采用 Heursure 准则, 确保在不同频段中进行有效的去噪。

6) 应用多阈值处理。通过将不同频段的小波包分解系数与对应的阈值准则相结合, 可以避免传统方法中可能出现的去噪过度或去噪不足的问题。例如, 对于信号占优的低频部分使用 Minimaxi 阈值准则, 而噪声占优的高频部分则使用 Heursure 阈值准则, 从而提高去噪精度。

7) 重构原信号。将滤波后的 IMF 信号分量与剩余低频 IMF 分量一起重构原始信号, 最终得到去噪后的海杂波信号。

为了验证不同阈值准则的去噪效果, 设计实验对比单一阈值准则与所提出的多准则组合 (Minimaxi-Rigrsure-Heursure) 的性能差异。选取 #30hh 第 7 距离单元海杂波样本作为测试集, 以信噪比 (signal-to-noise ratio, SNR) 和均方根误差 (root mean square error, RMSE) 作为核心评估指标, 结果如表 1 所示。

表 1 不同阈值准则的去噪效果比较

Table 1 Denoising performance comparison of different thresholding criteria

阈值准则	硬阈值	Minimaxi	Rigrsure	Heursure	多准则去噪
SNR	14.523	17.215	19.438	22.456	22.637
RMSE	0.0527	0.0382	0.0317	0.0297	0.0289

实验结果表明, 相较于任何单一阈值准则, 所提出的 Minimaxi-Rigrsure-Heursure 多阈值准则组合策略取得了最佳的去噪效果, 其 SNR 和 RMSE 均优于对比的各类单一阈值准则。充分证明了依据海杂波信号不同频段特性自适应匹配相应阈值准则策略的有效性。

通过以上步骤, 小波包多阈值去噪方法能够有效地去除信号中的噪声, 并最大限度地保留信号的关键特征, 显著提升了海杂波信号的去噪效果。尤其在处理复杂的非平稳信号时, 具有显著的优势。

## 2 哈里斯鹰优化算法优化长短期记忆网络

### 2.1 哈里斯鹰优化算法

哈里斯鹰优化算法汲取了哈里斯鹰捕猎行为的灵

感,尤其是其团体合作与突袭策略。哈里斯鹰的捕猎方法展现了多只鹰协同作战的智慧,这些鹰从不同方向发起进攻,试图在猎物不经意间发动攻击。这种策略能够根据猎物的逃逸模式和环境的动态变化做出及时调整。由此,哈里斯鹰优化算法模拟了这种灵活性和适应性,在优化过程中实现全局搜索与局部精细化操作。

该算法通过模拟哈里斯鹰的两种主要行为模式——探索行为与开发行为,来实现目标函数的优化。探索阶段侧重于全局搜索,而开发阶段则注重局部搜索与精细优化。

### 1) 探索行为

在哈里斯鹰优化算法的探索阶段,当某一哈里斯鹰的适应度值  $|E| \geq 1$  该鹰会在整个搜索空间内进行随机探索,寻找潜在的解。这一行为模式类似于哈里斯鹰在猎物逃逸初期的广泛搜寻。该阶段通过增加搜索范围,避免陷入局部最优,从而提高全局搜索的效率。

哈里斯鹰的栖息点选择基于猎物的分布以及群体中心的坐标信息。每只鹰根据与群体中心之间的相对位置来调整自己的移动轨迹,从而实现全局范围内的搜索。具体而言,哈里斯鹰的位置更新可以表示为:

$$x_i^{t+1} = x_i^t + r(p_i - p_{center}) \quad (8)$$

式中:  $x_i^{t+1}$  表示哈里斯鹰在第  $t+1$  次迭代的位置;  $x_i^t$  是当前位置;  $p_i$  和  $p_{center}$  分别代表哈里斯鹰和群体的位置;  $r$  为随机系数。

### 2) 开发行为

当哈里斯鹰的适应度  $|E| < 1$  时,表示该鹰已经接近猎物,进入了开发阶段。在此阶段,哈里斯鹰通过一系列围猎策略来进一步缩小解的搜索空间,以优化当前解。开发行为会根据能量差值与随机数的比较来选择合适的策略,从而实现局部优化。

开发阶段包含 4 种主要的围猎策略。

**策略 1: 软包围。**在适应度接近 0.5 时,哈里斯鹰采用软包围策略。该策略通过逐渐缩小围猎范围,使猎物逐步接近哈里斯鹰的攻击范围。哈里斯鹰根据猎物当前位置与自己的相对距离调整自己的位置。数学公式表示为:

$$x_i^{t+1} = x_i^t + a \cdot (p_{prey} - x_i^t) \quad (9)$$

式中:  $a$  为调节系数;  $p_{prey}$  是猎物当前的位置。

**策略 2: 硬包围。**当适应度值小于 0.5 时,哈里斯鹰会采取硬包围策略。在这种情况下,哈里斯鹰围绕猎物实施紧密包围,猎物的逃逸空间受到极大限制。此时,哈里斯鹰不再进行跳跃,而是保持在原地等待猎物的最终捕捉。此策略的数学模型为:

$$x_i^{t+1} = x_i^t + \beta \cdot (p_{prey} - x_i^t) \quad (10)$$

其中:  $\beta$  为常数,表示围捕的速度。

**策略 3: 高速俯冲软包围。**在猎物的逃逸能力较弱

时,哈里斯鹰会执行高速俯冲进行突袭。如果突袭未能成功,哈里斯鹰则会通过随机游走(Levy 飞行)返回初始位置,继续搜索。该策略结合了软包围和快速突袭的特点,具有较强的适应性,公式如下:

$$x_i^{t+1} = x_i^t + \lambda \cdot (S \odot D) \quad (11)$$

式中:  $\lambda$  为步长;  $S$  为随机向量;  $D$  代表问题维度;  $\odot$  表示逐元素乘积。

**策略 4: 高速俯冲硬包围。**当猎物处于极度危险的情况下,哈里斯鹰会执行高速俯冲并同时采取硬包围策略。此时,哈里斯鹰会根据群体中心与猎物之间的距离调整攻击策略,快速缩小猎物逃逸的空间。如果突袭未能成功,哈里斯鹰将启动随机游走并返回原点,公式如下:

$$x_i^{t+1} = x_i^t + \gamma \cdot (p_{center} - p_{prey}) \quad (12)$$

式中:  $\gamma$  为速度因子,表示哈里斯鹰的飞行速度。

通过这些策略的灵活切换,哈里斯鹰能够在探索阶段与开发阶段之间找到平衡,实现对目标函数的高效优化。哈里斯鹰优化算法通过模拟自然界中哈里斯鹰的行为,能够在全局搜索和局部搜索之间实现高效的调整,从而有效避免局部最优解的困扰。

## 2.2 长短时记忆神经网络

在混沌时间序列预测领域,基于相空间重构的数据可通过长短期记忆网络实现有效单步预测。作为传统循环神经网络(recurrent neural network, RNN)的改进架构,LSTM 通过独特的门控机制有效克服了 RNN 在捕捉长程依赖关系时存在的梯度消失缺陷<sup>[8-10]</sup>。相较于普通 RNN 的单一非线性变换结构,LSTM 创新性地引入三重复合门控单元——遗忘门、输入门与输出门,显著提升了网络对时间序列长期依赖特征的建模能力。其核心优势在于循环层的时间维度信息传递机制:通过将前一时刻的隐状态记忆  $h_{t-1}$  与  $x_t$  当前输入进行非线性融合,LSTM 在保留历史状态的同时动态学习序列的时序演化规律,从而实现对混沌系统动态特性的精准建模,其结构如图 2 所示。

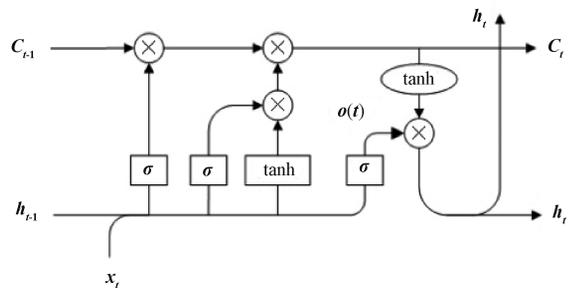


图 2 LSTM 结构

Fig. 2 Structure diagram of LSTM

从计算动力学的视角,LSTM 的门控系统通过构建多维信息流控制通道,为时间序列的长期依赖建模提供了

结构化解决方案。具体而言,遗忘门通过 Sigmoid 函数量化历史记忆的衰减系数,输入门调控当前特征向细胞状态的注入强度,输出门则负责解耦隐状态与更新后细胞状态的映射关系。3 类门控的协同作用体现为选择性遗忘冗余历史信息以降低噪声干扰,自适应提取有效时序特征以增强模式辨识,以及精准控制状态信息的传播路径以维持梯度稳定性。这种动态平衡机制可形式化表示为门控参数的联合优化过程,LSTM 的计算公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (13)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (14)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (15)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (16)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (17)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (18)$$

式中: $i_t$  为输入门; $f_t$  为遗忘门; $o_t$  为输出门; $h_{t-1}$  为前一时刻隐层状态; $h_t$  为当前时刻隐层状态; $x_t$  为当前时刻输入; $\tilde{C}_t$  为临时单元状态; $C_t$  为当前时刻单元状态; $C_{t-1}$  为上一时刻单元状态。

遗忘门 $f_t$  决定哪些信息应被丢弃,通过 Sigmoid 函数输出介于 0~1 之间的值,控制信息的遗忘程度。记忆门

(由输入门 $i_t$  和临时单元状态 $\tilde{C}_t$  共同作用)负责更新单元状态,它结合 Sigmoid 和 Tanh 激活函数,以决定哪些信息存储和更新。最后,输出门 $o_t$  利用当前单元状态 $C_t$ ,通过 Sigmoid 和 Tanh 函数生成当前的隐层状态 $h_t$ ,作为网络输出。通过这三者的协作,网络能够动态管理信息流,实现对长期与短期记忆的有效控制。

### 2.3 HHO-LSTM 预测模型

为了进一步提升 LSTM 网络在时间序列预测任务中的性能,本文将 HHO 算法引入 LSTM 模型的超参数优化过程中,构建了一种基于 HHO 优化的 LSTM 预测模型。该模型结合了 HHO 在全局搜索与局部开发方面的优越性能,有效克服了传统 LSTM 中超参数设置依赖经验、模型训练易陷入局部最优等问题,从而提高了模型的预测精度与泛化能力。

在构建 HHO-LSTM 模型之前,首先对原始时间序列数据进行归一化处理,以增强模型训练的稳定性 and 收敛速度。为了挖掘时间序列的动态特征,采用相空间重构方法将一维数据嵌入高维空间。其中,嵌入维数和时间延迟分别通过 C-C 方法和平均互信息法确定,以确保重构后的数据更好地表征系统的非线性动力学特性。

HHO 算法模拟哈里斯鹰在捕猎过程中的围攻策略,具备良好的全局探索能力和局部开发能力。在 HHO-LSTM 模型中,HHO 用于自动优化 LSTM 模型的关键超参数,包括隐藏层神经元数量、学习率、batch size、dropout

率和训练迭代次数等。这些参数构成了 HHO 的搜索变量空间,通过不断迭代寻优,使模型在训练集和验证集上的预测误差最小。为此,本文以 RMSE 作为适应度函数,其计算公式如下:

$$Fitness = \frac{1}{\sigma_y} \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (19)$$

式中: $y_i$  表示实际值; $\hat{y}_i$  表示模型预测值; $N$  为样本数量。

为了进一步提升 HHO 算法在超参数优化中的性能,本文对其初始化机制和搜索策略进行了改进。包括引入 Sobol 低差序列替代随机初始化,提升初始种群的多样性与搜索空间覆盖率;采用自适应逃逸因子,根据迭代进度动态调整鹰与猎物之间的能量差异,以提升后期的收敛速度与搜索精度;在局部开发阶段引入 Levy 飞行策略,加强算法在局部区域的搜索能力。这些改进在保证全局搜索能力的同时,显著提升了搜索效率和解的质量。

HHO 优化得到的最优超参数被用于 LSTM 模型的结构配置与训练阶段。模型包括输入层、若干 LSTM 隐藏层、Dropout 层以及输出层,训练过程中采用 Adam 优化器以加速收敛,并引入 Early Stopping 策略避免过拟合现象。最终训练得到的 HHO-LSTM 模型在测试集上进行验证,评估其预测精度与泛化能力。

## 3 基于 IVMD-WPD-HHO-LSTM 的海杂波背景下的目标检测

在海杂波背景下进行小目标检测面临显著的挑战,主要由于海杂波信号的强噪声干扰和高度非平稳性。为克服这些问题,本文提出了一种结合改进变分模态分解、小波包多阈值去噪 (wavelet packet multi-threshold denoising, WPD)、哈里斯鹰优化算法和长短时记忆网络的方法。该方法通过多层次的信号处理与深度学习模型优化,旨在提高小目标检测的精度与抗干扰能力。首先,原始的海杂波信号经过归一化处理,消除不同信号源之间的量纲差异。而后,采用 IVMD 将信号自适应地分解为多个频带模态,避免传统 VMD 方法中的模式混叠问题,并去除噪声模态,保留有用信号成分。接下来,通过小波包多阈值去噪进一步抑制高频噪声,小波包变将信号映射到小波包域,采用多阈值方法去除低幅度噪声系数,保留信号的主要特征。这一去噪过程在更细粒度的频域上进行处理,显著提升信号的清晰度和信噪比,为后续的小目标检测提供更纯净的输入信号。

去噪后的模态通过加权求和重构为平稳的海杂波信号,而后应用相空间重构技术将信号映射到高维空间,提取信号的时间依赖特征。相空间重构能够充分反映信号的非线性特征,为 LSTM 模型提供丰富的动态信息。在此基础上,采用哈里斯鹰优化算法优化 LSTM 的超参数,

通过全局优化算法对 LSTM 的关键超参数(包括隐藏层神经元数量和学习率)进行寻优,进而提升 LSTM 模型的预测性能。训练后的 LSTM 模型能够捕捉信号中的时间依赖关系,并通过误差分析识别信号中的小目标。当预测误差超过设定阈值时,可以准确判断信号中是否存在小目标。最终,本文提出的 IVMD-WTD-HHO-LSTM 小目标检测方法,通过多层次信号处理和深度学习优化,有效提升了小目标检测的精度与抗干扰能力,为复杂海杂波环境下的小目标检测提供了一个高效、可靠的技术方案。

本文方法的整体检测流程如图 3 所示,充分结合了信号处理的自适应性与深度学习模型的预测能力,为复杂背景下微弱目标的高效检测提供了新的思路与方法支持。

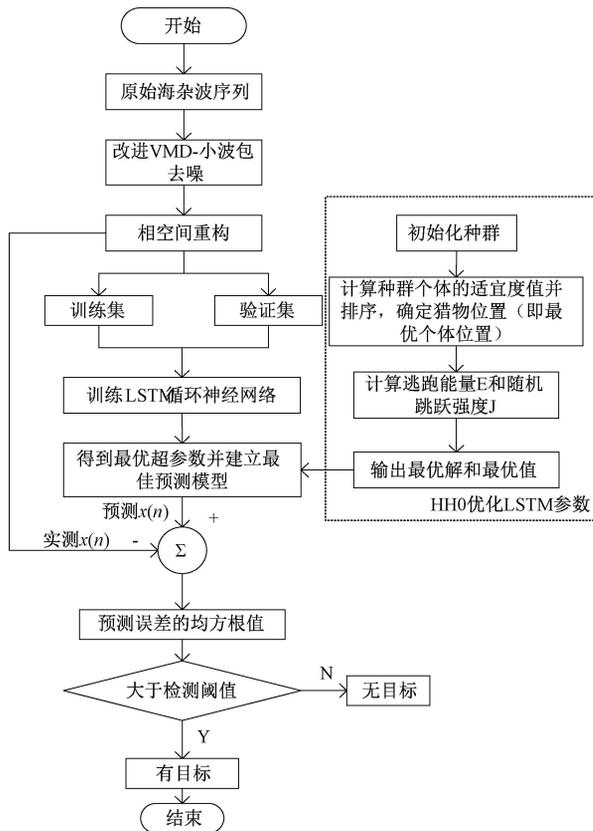


图 3 检测流程

Fig. 3 Detection flow chart

### 4 仿真实验

为了验证改进 IVMD-WPD-HHO-LSTM 检测模型的有效性,使用加拿大 McMaster 大学的 IPIX 雷达实测海杂波数据 (<http://soma.mcmaster.ca/ipix.php>, 2012. 10. 11)。本文主要选择 # 17hh、# 26hh、# 40hh、# 30hh、# 280hh, 信噪比分别为 18.9、4.3、9.7、-0.3、4.1 dB。每组数据有 14 个距离单元,包括目标单元和海

杂波单元,且每个距离单元有 131 072 个采样点。

#### 4.1 实测海杂波经 IVMD-WPD 去噪

为验证改进变分模态分解-小波包分解联合去噪方法在低信噪比海杂波环境下的有效性,选取 #26hh 雷达第 7 距离单元的 2 000 个脉冲数据进行验证实验。该单元信噪比为 4.3 dB,具有典型的海杂波非线性特征与强噪声耦合特性。

实验的目标是评估所提出方法在噪声背景下对海杂波的去噪效果,去噪过程分为 4 个阶段。

1) 数据预处理。对原始回波数据进行归一化处理,其归一化公式为:

$$\hat{x}(t) = \frac{x(t) - \mu_x}{\sigma_x} \quad (20)$$

式中:  $\mu_x$  为数据均值;  $\sigma_x$  为标准差;处理后信号动态范围约束在  $[-1, 1]$  区间。

2) IVMD 自适应分解。利用自适应粒子群优化算法,确定最优分解参数为模态数  $k = 8$ 、二次惩罚因子  $\alpha = 2\ 800$ ,将原始信号分解为 8 个具有物理意义的 IMF 分量。接着,通过分析每个模态的自相关特性,筛选出包含噪声的模态 (BLIMF4~6),并保留前 3 个主要模态用于信号重构。

3) WPD 多阈值去噪。在 IVMD 分解的基础上,对筛选出的含噪模态进行精细的小波包分解。采用 db4 小波基函数,并设定分解层数为 3,以实现多层次的信号去噪。通过改进的阈值函数对各频带中的噪声进行滤除,同时保留信号的主要特征。相较于传统的小波阈值去噪方法,WPD 能够在更加细化的频域上进行去噪处理,从而进一步提升信号的清晰度和信噪比。

4) 信号重构。在经过多重阈值处理后,各频带的小波包系数将被用来重构为滤波后的 IMF 信号。然后,将去噪后的 IMF 信号与剩余的低频 IMF 信号结合,进行进一步的信号重构,最终得到去噪后的海杂波信号。

图 4 所示为原始海杂波信号、经过改进 IVMD-WPD 去噪后的信号以及去噪过程中滤除的噪声成分。从图 4 可以看出,原始海杂波信号中存在明显的噪声“凸起”。经过改进 IVMD-WPD 去噪处理后,信号变得更加平滑,并且原始信号的特征尖峰得到了较好的保留。与之相比,去噪后的信号与改进 IVMD-WPD 去噪后的信号形态非常相似,这表明该方法能够有效地去除噪声,并在避免二次去噪时丢失有用信息的同时保持信号的主要特征。

将此方法与 EMD<sup>[18]</sup>、VMD<sup>[4]</sup>、WOA-VMD<sup>[7]</sup> 方法进行对比,利用 RMSE 评判去噪效果的优劣,RMSE 越低表示去噪性能越好。对比结果如表 2 所示。本文的去噪后的均方根误差均小于其他 3 种方法,具有较好的去噪效果。

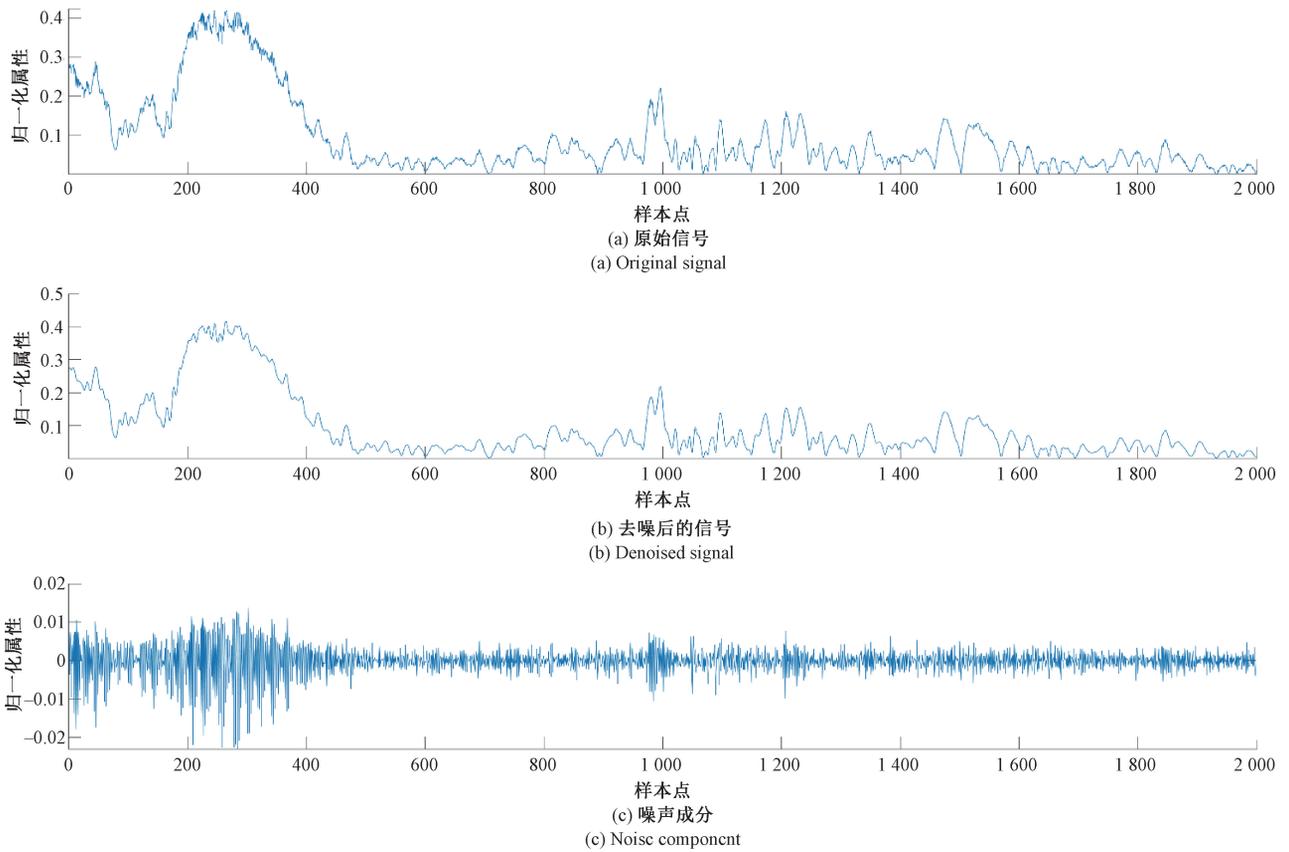


图 4 海杂波去噪前后对比

Fig. 4 Comparison of sea clutter signals before and after denoising

表 2 不同去噪方法的效果比较

Table 2 Performance comparison of various denoising methods

	EMD	VMD	WOA-VMD	本文方法
去噪前 RMSE	0.012 4	0.012 5	0.012 3	0.012 4
去噪后 RMSE	0.003 2	0.000 55	0.000 29	0.000 23

#### 4.2 HHO-LSTM 的海杂波检测性能研究

为了验证 HHO-LSTM 预测模型在海杂波背景下微弱目标检测中的有效性, 本文将径向基函数(radial basis function, RBF)、LSTM<sup>[19]</sup>、WOA-LSTM<sup>[15]</sup>与 HHO-LSTM 进行对比实验。在相同实验条件下, 选取#280hh 组无目标单元中的 2 000 个数据点进行预测, 并以 RMSE 作为主要评估指标, 对各模型的预测性能进行系统对比分析。对比结果如表 3 所示, 本文的预测模型的均方根误差显著低于其他模型, 能够更加精准的捕捉微弱目标信号。

#### 4.3 IVMD-WPD-HHO-LSTM 实测海杂波噪声抑制效果

为验证所提出的 IVMD-WPD-HHO-LSTM 算法在海杂波背景下的噪声抑制和微弱目标检测性能, 本文选取了多组不同海况下的数据进行系统实验。通过对比去噪前后预测误差的变化, 评估在不同信噪比条件下的检测

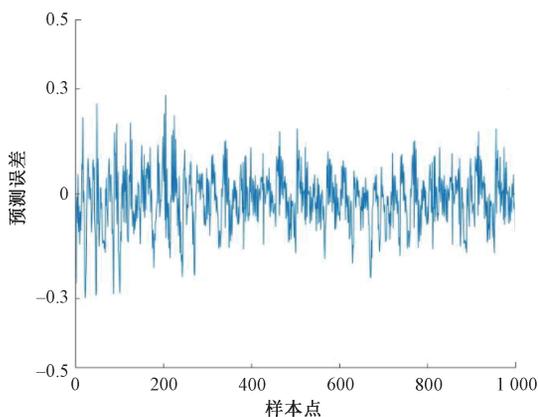
精度、抗干扰能力以及虚警抑制效果。

表 3 #280hh 不同预测模型的效果比较

Table 3 Comparison of different prediction models for #280hh

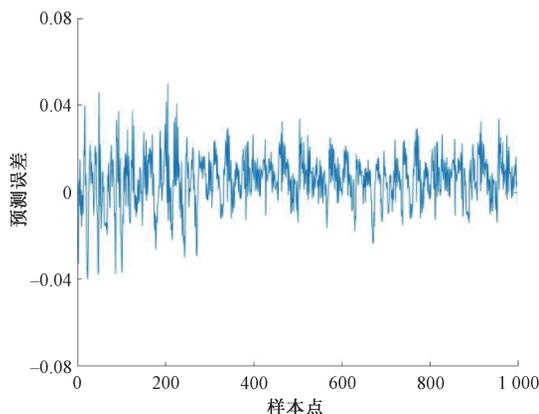
模型	RMSE
RBF	0.079 458
LSTM	0.053 226
WOA-LSTM	0.015 953
本文	0.013 765

实验选取#40 组海情 ( $SNR = 9.7$  dB) 第 7 距离单元的 3 000 个原始海杂波脉冲数据为样本进行实验, 去噪前后预测误差对比如图 5 所示。首先, 采用粒子群优化算法确定 IVMD 分解的最优参数, 得到了模态数  $K = 10$  和惩罚因子  $\alpha = 3 000$ 。接着, 通过改进的 C-C 方法确定了相空间重构参数, 得到了嵌入维数  $m = 4$  和延迟时间  $\tau = 3$ , 从而构建了 12 维输入向量以准确表征海杂波的动力学特性。去噪后的数据集按 2 : 1 的比例划分为训练集和验证集, 利用改进的哈里斯鹰优化算法优化 LSTM 的超参数, 最终确定隐藏层神经元数为 98, 最大迭代次数为 51。



(a) #40hh第7距离单元未去噪预测误差

(a) Prediction RMSE of non-denoised range cell 07 (#40hh dataset)



(b) #40hh第7距离单元去噪后预测误差

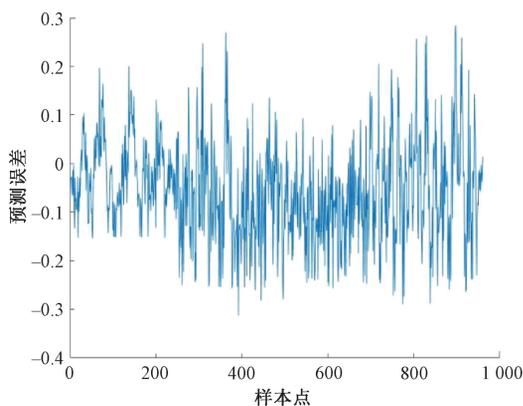
(b) Prediction RMSE of denoised range cell 07 (#40hh dataset)

图 5 #40 组海情第 7 距离门海杂波去噪前后预测误差对比  
Fig. 5 Comparative analysis of prediction RMSE for sea clutter in range gate 07 (#40 dataset) before and after denoising

图 5(a) 中,原始海杂波信号(未经任何预处理)的预测误差其时域分布特征较为平稳,在整个观测区间内未显现出明显的异常或突变,表明微弱目标信号完全湮没于强海杂波及环境噪声背景之中。在经过 IVMD-WPD 处理后,图 5(b)中,约 150 个样本点附近的预测误差出现了显著波动,微弱信号被清晰地识别出来。通过对比图 5(a)和(b)的结果可以得出,所提出的 IVMD-WPD 噪声抑制算法在较高信噪比条件下,能够有效地抑制背景噪声,并显著增强微弱目标的可检测性。

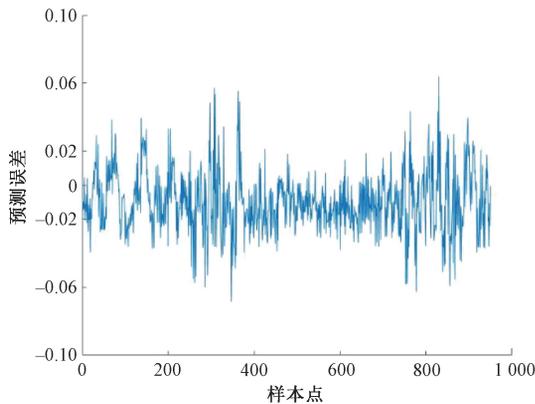
为验证实验的普适性,选取高信噪比数据(#17 组,  $SNR = 18.9 \text{ dB}$ )重复上述实验流程。去噪前的实验结果如图 6(a)所示,均方根误差为 0.055 9,且从预测误差中无法有效识别微弱信号的存在。应用 IVMD-WPD 噪声抑制算法进行去噪处理后,预测误差如图 6(b)所示,去噪后的均方根误差降至 0.024 9,下降幅度为 55%。

另外,#40 组海情的信噪比为 9.7 dB,而#17 组的信噪比为 18.9 dB,两者均属于高信噪比环境。在这一条件



(a) #17hh第9距离单元未去噪预测误差

(a) Prediction RMSE in non-denoised range cell 09 (#17hh dataset)



(b) #17hh第9距离单元去噪后预测误差

(b) Post-denoising prediction RMSE in range cell 09 (#17hh dataset)

图 6 #17 组海情第 9 距离门海杂波去噪前后预测误差对比  
Fig. 6 Comparative analysis of prediction RMSE for sea clutter in range gate 09 (#17 dataset) before and after denoising

下,前述结果表明,IVMD-WPD 噪声抑制算法能够有效提高信号检测性能,且去噪前后预测误差的对比差异显著,表明预测精度得到了明显提升。

为评估算法在复杂环境下的适应能力,选取海清条件差的海杂波数据进行实验。#30 组海情信噪比为  $-0.3 \text{ dB}$ ,属于低信噪比海杂波,利用第 7 距离门进行实验实验结果如图 7 所示。

从图 7(a)可以看出,未经去噪的预测误差在约 900 个样本点附近出现较大起伏,但与剩余样本点相比,波动幅度并不明显,去噪前的 RMSE 为 0.041 6。经过 IVMD-WPD 噪声抑制算法处理后,剩余样本点的噪声得到有效抑制,微弱信号得以增强,预测误差曲线中可以清晰地观察到目标信号。去噪后的均方根误差降至 0.028 9,下降幅度为 30%。这一结果表明,在噪声水平显著提高的情况下,IVMD-WPD 算法仍能有效压制背景噪声,保留目标信号的特征。

与未经处理的信号相比,去噪后的预测误差曲线更加平滑,目标信号保持了较强的可分辨性。此外,RMSE

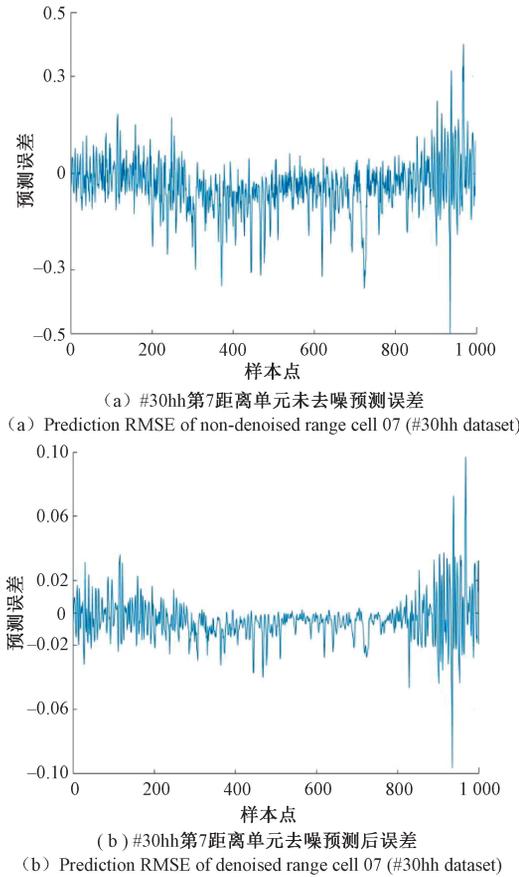


图 7 #30 组海情第 7 距离门海杂波去噪前后预测误差对比图

Fig. 7 Comparative analysis of prediction RMSE for sea clutter in range gate 07 (#30 dataset) before and after denoising

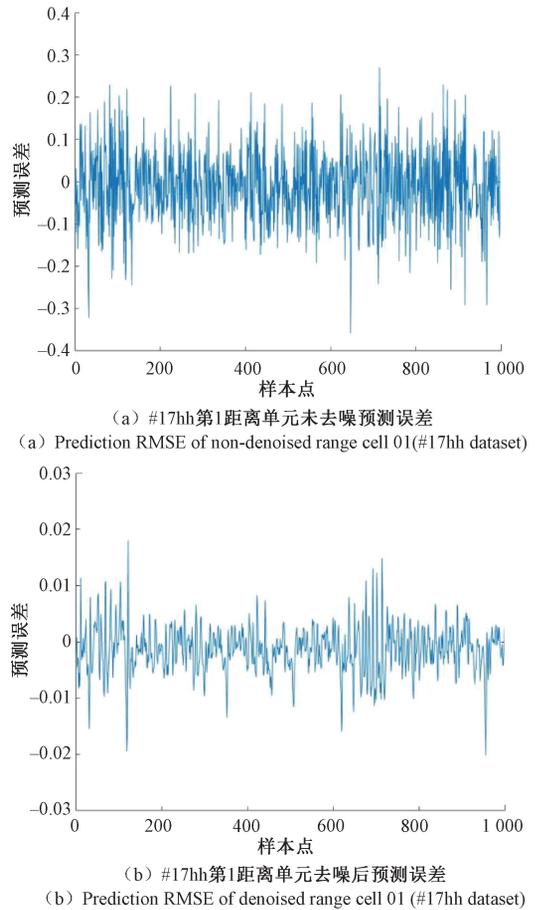


图 8 #17 组海情第 1 距离门海杂波去噪前后预测误差对比图

Fig. 8 Comparative analysis of prediction RMSE for sea clutter in range gate 01 (#17 dataset) before and after denoising

的显著下降进一步证明了该算法在低信噪比环境中依然具有较好的检测性能,有效降低了误检率和漏检率。

为进一步验证算法对虚警的抑制能力,在#17组数据中选取了不含目标的距离门作为对照实验。实验发现,未经处理的预测误差曲线仍然存在较为显著的异常波动,易被误判为目标;而 IVMD-WPD 处理后,预测误差曲线趋于平稳,无明显突起波动,表明该方法能有效过滤纯噪声信号,避免产生虚假目标响应,从而降低整体系统的虚警率。

从图 5~8 可以直观地通过预测误差判断测量的距离单元是否含有小目标,但缺乏足够的定量数据支持。为了进一步验证 IVMD-WPD-HHO-LSTM 模型的准确性,本文计算了#280hh 组的 14 个距离单元的预测误差均方根值,并将结果与文献[19]中的相应数据进行了对比,具体数据如表 4 所示。

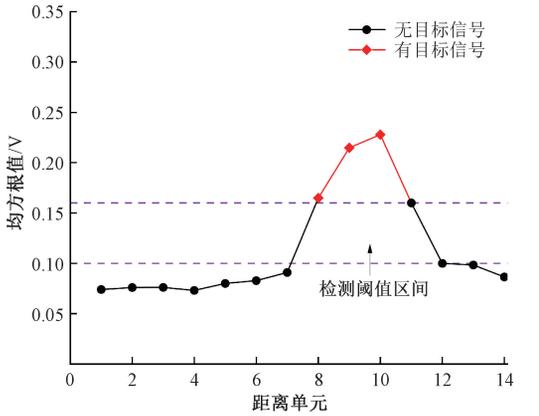
表 4 预测误差均方根值的折线图如图 9 所示。从图 9 可得出,文献[19]方法中纯海杂波单元的最大预测误差均方根值为 0.100 049,而含目标单元的最小值为

表 4 预测误差均方根值对比

Table 4 Benchmarking of prediction root mean square error

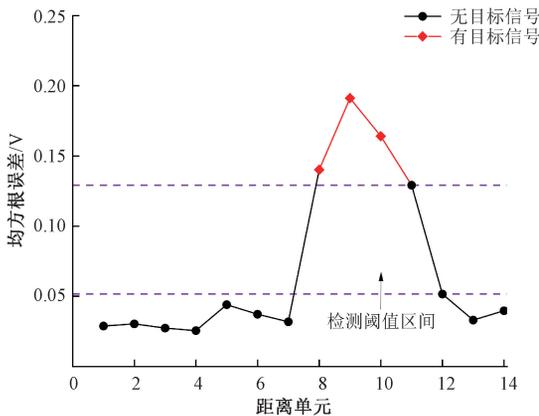
海情标号	IPIX 数据集	本文
#17hh 组第 1 距离门	0.074 084	0.028 89
#17hh 组第 2 距离门	0.076 035	0.030 41
#17hh 组第 3 距离门	0.076 123	0.027 40
#17hh 组第 4 距离门	0.073 149	0.025 60
#17hh 组第 5 距离门	0.080 107	0.044 06
#17hh 组第 6 距离门	0.082 909	0.037 31
#17hh 组第 7 距离门	0.091 058	0.031 87
#17hh 组第 8 距离门(含目标)	0.164 875	0.140 14
#17hh 组第 9 距离门(含目标)	0.214 809	0.191 11
#17hh 组第 10 距离门(含目标)	0.227 856	0.164 06
#17hh 组第 11 距离门(含目标)	0.160 051	0.129 20
#17hh 组第 12 距离门	0.100 049	0.051 64
#17hh 组第 13 距离门	0.098 425	0.033 09
#17hh 组第 14 距离门	0.086 569	0.039 78

0.160 051, 对应检测阈值的区间为 (0.100 049, 0.160 051), 右端点为左端点的 1.6 倍。相比之下, 本文提出的方法显著改善了预测精度: 纯海杂波单元最大误差降至 0.051 64, 含目标单元最小误差为 0.126 370, 优化后的检测阈值区间为 (0.051 64, 0.126 370), 右端点与左端点的比值提升至 2.44。与文献[19]相比, 本文模型检测能力提升了 52%。



(a) 文献[19]预测误差均方根

(a) Prediction root mean square error in reference [19]



(b) 本文预测误差均方根误差

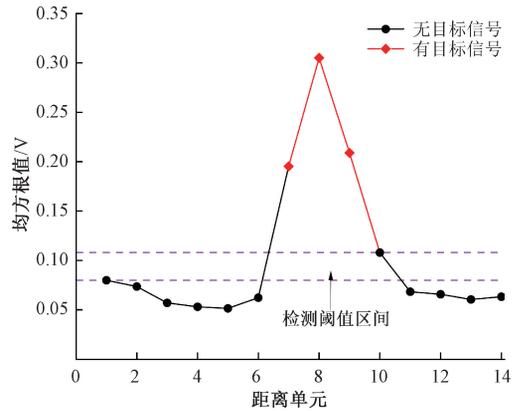
(b) Proposed framework prediction RMSE with statistical validation

图 9 #17hh 预测误差均方根值折线图

Fig. 9 #17hh forecast error root mean square value line plot

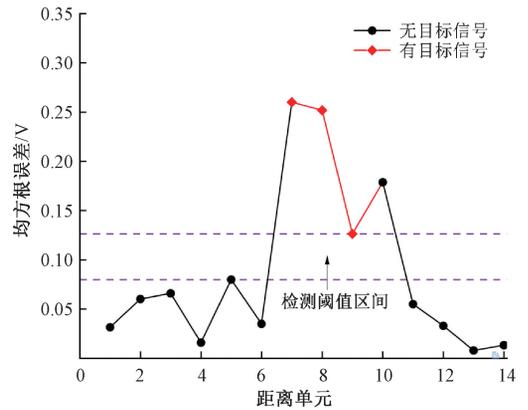
为验证本文检测模型的有效性, 对#280hh 数据重复进行误差分析, 并与文献[19]结果进行对比, 如图 10 所示。文献[19]中#280hh 数据的检测阈值区间为 (0.079 98, 0.108 02), 右端点为左端点的 1.36 倍; 本文方法对应的检测阈值区间为 (0.094 61, 0.177 40), 右端点为左端点的 1.874 倍。对比结果表明, 本文模型的检测能力较文献[19]提升了 35%。

综上所述, IVMD-WPD-HHO-LSTM 在实测海杂波数据中的应用效果显著。在高 SNR 条件下, 算法能够突出微弱目标特征, 提高检测准确性; 在低 SNR 环境下, 依然保持良好的抗干扰能力; 在无目标情况下, 具备较强的虚



(a) 文献[19]预测误差均方根

(a) Prediction root mean square error in reference [19]



(b) 本文预测误差均方根

(b) Proposed framework prediction RMSE with statistical validation

图 10 #280hh 预测误差均方根值折线图

Fig. 10 #280hh forecast error root mean square value line plot

警抑制效果。多组海情实验验证了该方法在不同条件下的普适性与稳定性, 为复杂海杂波环境中的微弱目标检测提供了有力支持。

## 5 结 论

本文提出了一种基于信号处理与深度学习模型相结合的 IVMD-WPD-HHO-LSTM 海杂波检测方法, 通过对海杂波数据进行 IVMD 与 WPD 去噪处理, 结合 HHO 优化 LSTM 网络的超参数, 显著提升了微弱目标在复杂海杂波背景下的检测性能。实验结果表明, 所提方法在高信噪比和低信噪比条件下均具有较高的检测精度, 尤其是在低信噪比的情况下, 仍能有效抑制背景噪声并准确识别微弱目标。相比传统的 LSTM 方法, 所提出的 IVMD-WPD-HHO-LSTM 方法至少提高了 35% 的检测能力, 且具有较强的抗干扰能力和虚警抑制效果。

通过多组海况下的实验验证, 本文方法在不同海

域与海况中均表现出了良好的稳定性和适应性,为海上微弱目标的检测提供了一个有效的解决方案。尤其在复杂的海杂波环境中,本文方法能够有效地提取目标信号特征,增强目标的可检测性,具有较高的应用价值,特别是在海上监控与安全领域。

然而,本文方法也存在一些局限性。算法的计算复杂度较高,可能在实时性要求较高的应用中面临挑战,因此需要进一步优化。模型的泛化能力和针对特定复杂海况的适应性仍有待提升。未来的研究可以着重于优化算法效率、提升模型的实时性能,并进一步探索深度学习与传统信号处理方法的结合,以增强模型的抗干扰能力和泛化能力。

### 参考文献

- [ 1 ] HAYKIN S, XIAO B L. Detection of signals in chaos[J]. Proceedings of the IEEE, 1995, 8(1):95-122.
- [ 2 ] 张国栋. 基于海杂波混沌特性的杂波抑制的研究[D]. 大连:大连海事大学,2019.
- ZHANG G D. Research on clutter suppression based on chaotic characteristics of sea clutter[D]. Dalian: Dalian Maritime University, 2019.
- [ 3 ] DONOHO D L. De-noising by soft-thresholding [J]. IEEE Transactions on Information Theory, 2002, 41(3): 613-627.
- [ 4 ] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences, 1998, 454(1971): 903-995.
- [ 5 ] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2013, 62(3): 531-544.
- [ 6 ] JIANG S, XING H Y, WANG J J. Sea clutter hybrid denoising algorithm based on VMD [C]. 14th IEEE International Conference on Electronic Measurement & Instruments (ICEMI). IEEE, 2019: 551-558.
- [ 7 ] 周星,行鸿彦,叶如,等. 基于优化变分模态分解的海杂波去噪方法[J]. 电子测量与仪器学报, 2023, 37(11):81-90.
- ZHOU X, XING H Y, YE R, et al. Sea surface weak target detection based on optimized long short-term memory network[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(11):81-90.
- [ 8 ] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: A search space odyssey[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 28(10): 2222-2232.
- [ 9 ] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [ 10 ] 王海峰,行鸿彦,陈梦,等. 基于SSA-SVM的海杂波背景下小信号检测方法[J]. 电子测量与仪器学报, 2022, 36(4):24-31.
- WANG H F, XING H Y, CHEN M, et al. Small signal detection method under sea clutter background based on SSA-SVM[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(4): 24-31.
- [ 11 ] MA L, WU J, ZHANG J, et al. Sea clutter amplitude prediction using a long short-term memory neural network[J]. Remote Sensing, 2019, 11(23): 2826.
- [ 12 ] 苏宁远,陈小龙,关键,等. 基于深度学习的海上目标一维序列信号目标检测方法[J]. 信号处理, 2020, 36(12):1987-1997.
- SUN N Y, CHEN X L, GUAN J. Target detection method for one-dimensional sequential signal of maritime target based on deep learning [J]. Journal of Signal Processing, 2020, 36(12): 1987-1997.
- [ 13 ] 吴涵,行鸿彦,李梦杰,等. 基于AWE-NRBO-BiLSTM的海面微弱目标检测[J]. 电子测量与仪器学报, 2025, 39(6):184-194.
- WU H, XING H Y, LI M J, et al. Sea surface weak target detection based on AWE-NRBO-BiLSTM [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 184-194.
- [ 14 ] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris hawks optimization: Algorithm and applications [J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [ 15 ] 祝健,尚尚,石依山,等. 基于改进WTD-SVD-WOA-LSTM方法的海杂波背景下小目标检测[J]. 电讯技术, 2024, 64(8):1219-1227.
- ZHU J, SHANG SH, SHI Y SH, et al. Small target detection under sea clutter background based on improved WTD-SVD-WOA-LSTM method[J]. Telecommunications Technology, 2024, 64(8): 1219-1227.
- [ 16 ] ZHAN Z H, ZHANG J, LI Y, et al. Adaptive particle swarm optimization[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2009, 39(6): 1362-1381.
- [ 17 ] 阎妍,行鸿彦. 基于小波包多阈值处理的海杂波去噪

方法 [J]. 电子测量与仪器学报, 2018, 32 (8): 172-178.

YAN Y, XING H Y. Sea clutter denoising method based on multi-threshold processing of wavelet packet [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(8): 172-178.

- [18] 王福友, 刘刚, 袁赣南. 基于 EMD 算法的海杂波信号去噪 [J]. 雷达科学与技术, 2010, 8(2): 177-182, 187.

WANG F Y, LIU G, YUAN G N. Sea clutter signal denoising based on EMD algorithm [J]. Radar Science and Technology, 2010, 8(2): 177-182, 187.

- [19] 阎妍. 海杂波中的噪声抑制及其微弱信号检测 [D]. 南京: 南京信息工程大学, 2022.

YAN Y. Noise suppression and weak signal detection in sea clutter [D]. Nanjing: Nanjing University of Information Science and Technology, 2022.

## 作者简介



**李梦杰**, 2024 年于洛阳师范学院获得学士学位, 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: 2972325021@qq.com

**Li Mengjie** received her B. Sc. degree from Luoyang Normal University in 2024. 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, 南通理工学院智能装备与系统专业带头人, 主要研究方向为微弱信号检测与处理、生物医学信号采集与处理、智能化电子测量技术与仪器。

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 & Technology, as well as the leader of the Intelligent Equipment and Systems program at Nantong University of Technology. His main research interests include weak signal detection, bio-medical signal collection and processing, and design of intelligent electronic measurement technology and instrument.



**吴涵**, 2023 年于成都信息工程大学获得学士学位, 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: 1842193327@qq.com

**Wu Han** received his B. Sc. degree from Chengdu University of Information Technology in 2023. Now he is a M. Sc. candidate at Nanjing University of Information Science and Technology. His main research interest includes weak signal detection.