

基于 AWE-NRBO-BiLSTM 的海面微弱目标检测 *

吴 涵^{1,2} 行鸿彦^{1,2} 李梦杰^{1,2} 杭陈雨^{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:针对强海杂波背景下传统方法难以检测海面微弱目标信号的问题,研究了混沌相空间重构理论和改进牛顿-拉夫逊优化算法(NRBO),提出了一种基于优化双向长短时记忆网络(BiLSTM)的混沌背景下微弱信号检测方法。将重构的相空间信号作为BiLSTM网络的输入,通过嵌入维度和延迟时间确定训练数据的长度,利用改进牛顿-拉夫逊优化算法优化BiLSTM模型的参数,使用自适应加权误差(AWE)损失函数训练模型,提高模型预测精度与运行速度,降低目标检测门限,结合BiLSTM模型进行单步预测,根据预测误差从强混沌背景噪声下检测微弱目标信号。以Lorenz混沌系统作为混沌背景设计仿真实验,对叠加的微弱信号进行检测,结果表明所提方法能有效检测微弱信号。使用IPIX实测数据和烟台对海探测数据进行预测实验,进一步证明了其有效性。

关键词:海杂波;微弱信号检测;BiLSTM;NRBO 算法

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

Weak target detection based on AWE-NRBO-BiLSTM in sea clutter background

Wu Han^{1,2} Xing Hongyan^{1,2} Li Mengjie^{1,2} Hang Chenyu^{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: To address the challenge of detecting weak target signals on the ocean surface under strong sea clutter backgrounds, this study investigates the theory of chaotic phase space reconstruction and the improved Newton-Raphson optimization algorithm. A novel method for weak signal detection in chaotic backgrounds is proposed, based on an optimized bidirectional long short-term memory network (BiLSTM). The reconstructed phase space signal is used as the input to the BiLSTM network, with the length of the training data determined by the embedding dimension and delay time. The parameters of the BiLSTM model are optimized using the improved Newton-Raphson optimization algorithm, and the model is trained with an adaptive weighted error (AWE) loss function. Both approaches work together to enhance prediction accuracy, improve runtime speed, and reduce the detection threshold. A single-step prediction is performed using the BiLSTM model, and weak target signals are detected from strong chaotic background noise by analyzing the prediction errors. Simulation experiments were conducted using the Lorenz chaotic system as the chaotic background to detect superimposed weak signals. The results demonstrate that the proposed method effectively detects weak signals. Further validation was carried out using the IPIX radar dataset and sea surface detection data from Yantai, confirming the method's robustness and effectiveness.

Keywords: sea clutter; week signal detection; BiLSTM; Newton-Raphson-based optimizer

0 引言

随着科技的不断发展,对海洋的认知与监测可以通过雷达来实现。雷达是海洋战场和对海探测场景的“眼睛”,若需进一步提升雷达的对海探测能力,对海杂波特性的深度化认知、精细化感知和充分化利用至关重要^[1]。海杂波是指在雷达系统中,来自海面的反射的杂波信号,这些信号对探测海面物体(如船只、小艇或浮标等)造成干扰,降低雷达系统的性能。因此,研究海杂波背景下的微弱信号检测方法有着重要意义。

海杂波背景下的弱、慢、小目标检测一直是信号处理领域的一个难点。其检测困难主要来源于4个方面^[2]:1)海杂波具有非线性、非平稳、非均匀特性,难以建模;2)强海杂波背景噪声下,微弱信号的回波被噪声淹没,信噪比低;3)海浪的运动姿态多变,有时会遮蔽和淹没目标;4)高功率的海尖峰随机出现,其时域与频域特征与目标回波有相似之处,容易导致探测器误报。

针对海杂波背景下的海面微弱信号检测问题,国内外学者提出了大量研究方法。早期的研究者对海杂波的研究集中在统计理论方面^[3],将其建模为分布模型,如瑞利分布、对数-正态分布、以及复合K分布,但其存在精度与泛化性的问题。20世纪末,Haykin等^[4]提出海杂波建模是一个预测问题,并用混沌系统对海杂波进行建模。随着统计学习理论的发展,支持向量机(support vector machine,SVM)理论出现,为研究小目标检测提供了新的思路。2010年Xing等^[5]提出了基于LS-SVM模型的微弱信号检测方法,优化了SVM模型,提高了预测精度。尽管通过核函数,SVM及其改进算法可以处理一定的非线性问题,但对于复杂的动态非线性关系,尤其是混沌时间序列预测,仍存在精度不足的问题。相比SVM等传统机器学习算法,神经网络在解决数据预测问题上有一定的优势。早期使用基于BP神经网络的预测模型,可以检测混沌背景中的微弱信号。近几年随着神经网络迅速发展,更多的改进神经网络模型被应用在数据预测问题上。递归神经网络(recurrent neural network,RNN)与长短时记忆网络(long short-term memory network,LSTM)^[6-7]作为传统神经网络的改进被应用在混沌时间序列预测问题中。2022年,Yan等^[8]提出了基于LSTM误差频域转换的检测方法,通过计算误差的多普勒频谱,从频域检测微弱信号,提高了LSTM模型的微弱信号检测效果。De等^[9]提出CNN-LSTM混合架构的监测模型,利用随时间变化的幅度浮动区分目标。Abdelkader等^[10]使用RNN-LSTM混合模型实现时间序列预测,提升了预测精度。2024年叶如等^[11]提出基于SSA-LSTM的海面微弱目标检测方法,相较于传统LSTM神经网络模型,其预测精度

与检测阈值都得到提升。

在使用LSTM模型检测海杂波背景下的微弱信号的研究中,仍然存在一些问题。LSTM具有单向信息处理的局限性,对数据上下文的建模能力不足。其迭代次数、学习率、隐藏层神经元层数与单元数等超参数对预测结果有一定影响,选择恰当的超参数十分重要,考虑到计算成本,遍历超参数空间以寻找全局最优解的方法是不现实的,需要采用元启发式算法寻找最优解。经典的元启发式优化算法^[12-14]如遗传算法、鲸鱼算法、麻雀算法、粒子群算法等虽具潜力,但存在一定缺陷。基于梯度的方法往往会收敛到局部最优解,非梯度方法则需要更高的计算能力,尤其是对于高维空间搜索的问题。此外,损失函数是神经网络模型的重要组成部分,而目前采用神经网络来解决海杂波背景下目标检测问题的研究通常没有对损失函数的选择与设计进行探讨。

针对以上问题,本文提出一种基于自适应加权误差损失(adaptive weighted error,AWE)与改进牛顿-拉夫逊优化算法(Newton-Raphson-based optimizer,NRBO)结合的双向长短时记忆网络(bi-directional long short-term memory,BiLSTM)的海杂波背景下微弱信号检测方法。使用BiLSTM代替传统的LSTM,并设计适合时序检测的损失函数,优化训练模型;结合NRBO算法优化超参数,克服梯度算法和非梯度算法的缺点,同时利用基于种群的优化方法的能力,降低预测成本,提高预测精度。为验证检测效果,使用Lorenz系统进行仿真实验,并分别采用IPIX海杂波数据集与烟台对海数据集的真实数据作为样本,检验不同海域下模型检测能力。

1 基本理论

在混沌时间序列的研究中,传统的线性方法往往无法有效揭示系统的复杂非线性特征,相空间重构技术通过时间延迟嵌入法将原本复杂的动态系统转化为可以进行分析的多维空间。此外,随着深度学习方法的发展,神经网络,特别是双向长短时记忆网络在序列数据处理中的优势逐渐显现,其能够捕捉序列中的长期依赖关系,是处理时间序列预测问题的重要工具。

1.1 混沌时间序列相空间重构

混沌系统是非线性动力学中的一种动态系统,其表面上似乎随机,但实际上是由确定性的规则所支配的。混沌系统的微小初始差异会随着时间推移被无限放大,导致系统的演化轨迹完全不同。混沌系统的演化轨迹并不周期性重复,但它们通常会收敛到一个特定的区域,这些区域称为吸引子(通常是分形结构,如奇异吸引子)。

传统的低维坐标系统无法揭示混沌系统复杂的动力学特征,因此混沌模型的建立和预测需要结合混沌理论

中的相空间重构技术。Takens 定理指出通过时间延迟嵌入法可以重构出与原系统拓扑等价的相空间。主流的相空间重构方法有 G-P 法、曹氏法、伪临近法和 C-C 法等。采用 C-C 法求解海杂波时间序列的嵌入维度 m 和延迟时间 τ , 对于海杂波时间序列 $\{x(i), i = 1, 2, 3, \dots, N\}$ 的重构空间序列 $\{X_n(i) = x_n(i), x_n(i + \tau), \dots, x_n(i + (m - 1)\tau)\} (n = 1, 2, \dots, M)$, 利用关联积分求解混沌特征奇异吸引子的关联维度, 并根据关联指数饱和值求得嵌入维度和嵌入延时窗。

1.2 双向长短时记忆网络

长短期记忆神经网络^[15]解决了传统递归神经网络中的梯度爆炸问题,使得网络的学习更加的稳定。LSTM 网络通过使用 LSTM 单元取代了一般 RNN 的隐藏单元, 使用输入门、遗忘门和输出门控制 LSTM 单元的状态更新。LSTM 的独特之处在于它包括 3 个门: 输入门 i_t 、遗忘门 f_t 和输出门 o_t , 这些门结构使得网络能够更有效地捕捉长距离的依赖关系, 具体工作原理如式(1)~(6)所示。

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

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

式中: h_{t-1} 为前一时刻隐藏层状态; h_t 为当前时刻隐藏层状态; 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; σ 为激活函数。遗忘门用于决定遗忘和丢弃的信息, 记忆门通过 sigmoid 函数和 tanh 函数决定需要更新的单元和更新的单元信息, 输出门根据单元状态, 通过 sigmoid 函数和 tanh 函数确定输出值。LSTM 的网络结构如图 1 所示。




图 1 LSTM 的网络结构

Fig. 1 The network structure of LSTM

双向长短时记忆网络^[16]相较于传统的单向 LSTM, 通过同时引入正向和反向两个 LSTM 模块, 能够捕获序列数据的前后文信息, 显著增强对上下文依赖的建模能

力, 其结构如图 2 所示。这种双向信息流机制使得 BiLSTM 在自然语言处理、序列标注和时间序列分析等需要全局语境理解的任务中表现更优。同时, 通过将正反向 LSTM 的输出进行结合, BiLSTM 能够生成更全面的特征表示, 尽管计算开销有所增加, 但其性能提升在许多应用场景中尤为显著。考虑到海杂波序列属于时间序列信号, 因此用 BiLSTM 来进行预测具有高度适配性。




图 2 BiLSTM 的网络结构

Fig. 2 The network structure of BiLSTM

1.3 自适应加权误差损失函数

在深度学习任务中, 损失函数用于衡量模型预测值与真实值之间的差异。传统的损失函数, 如均方误差、交叉熵等通常对所有样本或误差项赋予相同的权重, 但在实际应用中, 不同样本或误差项的重要性可能不同。

自适应加权误差损失函数通过动态调整不同样本或误差项的权重, 使模型能够更关注关键样本或误差较大的区域, 从而提高模型的鲁棒性和泛化能力。其计算公式如式(7)~(9)所示。

$$L(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N w_i (y_i - \hat{y}_i)^2 \quad (7)$$

$$w_i = 1 + \alpha \cdot \exp(|y_i - \hat{y}_i|) \quad (8)$$

$$L(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^N (1 + \alpha e^{|y_i - \hat{y}_i|}) (y_i - \hat{y}_i)^2 \quad (9)$$

式中: y_i 为真实值; \hat{y}_i 为预测值; w_i 为权重; L 为损失函数; N 为样本点数; α 为控制加权强度的超参数。

1.4 改进牛顿-拉夫逊优化算法

牛顿-拉夫逊法 (Newton-Raphson method, NRM) 是一种常用的求解方程根的方法, 而改进牛顿-拉夫逊优化算法是在 NRM 基础上发展起来的一种新型元启发式优化算法^[17]。NRBO 方法主要使用 Newton-Raphson 搜索规则 (Newton-Raphson search rule, NRSR) 和陷阱规避算子 (trap avoidance operator, TAO) 两种方法。其中, NRSR 将 NRM 拓展到多维度, 使用有限差分法近似梯度, 并基于梯度信息快速逼近局部最优解; TAO 引入临时吸引点, 通过吸引当前个体向临时吸引点移动以更新个体位置^[18]。算法实现步骤如下。

1) 设置初始参数: 确定种群规模、设置最大迭代次数、定义决策因子。

2) 初始化种群: 随机生成初始种群的位置向量, 作为初始解的集合。

3) 评估适应度函数: 计算种群每个个体的适应度值, 记录当前最优个体与次优个体。

4) 应用 NRSR 规则更新个体的位置。NRSR 表示如下:

$$NRSR = randn \times \frac{(X_w - X_b) \times \Delta x}{2 \times (X_w + X_b - 2 \times x_n)} \quad (10)$$

式中: $randn$ 表示均值为 0 且方差为 1 的正态分布随机数; X_w 表示最差位置; X_b 表示最佳位置; x_n 为当前位置; Δx 为扰动值。

5) 在 NRSR 迭代过程中, 使用 TAO 方法检测并避免陷入局部最优解。当检测到局部最优时, TAO 通过结合当前向量和最优向量的位置, 探索更优解, 从而有效跳出局部最优解的困境。

6) 重复迭代步骤, 直到达到最大迭代次数或适应度值收敛。

NRBO 算法通过引入 NRSR 利用梯度信息快速逼近局部最优解, 通过 TAO 动态调整搜索方向, 有效避免陷入局部最优陷阱, 从而增强全局搜索能力。这种结合局部精确搜索与全局探索的机制, 使得 NRBO 能找到局部最优解, 而且较大概率能收敛到全局最优解。

2 基于 AWE-NRBO-BiLSTM 的海杂波背景下微弱目标检测方法

海杂波信号通常表现出复杂的动态特征, 利用混沌系统的相空间重构方法, 可以有效捕捉海杂波的短时变化特征, 并使用神经网络模型进行短期预测。基于上述理论, 本文提出一种新的海杂波背景下微弱信号检测方法。设计 AWE-NRBO-BiLSTM 模型对重构后的海杂波信号进行短时预测, 并绘制相对幅度差值曲线。所提模型能够以较低的误差预测海杂波混沌系统, 但不会预测叠加在杂波中的微弱目标信号。对于海杂波系统, 模型的预测误差较小, 而对于目标回波。模型会产生较大预测误差, 因此借助误差峰值可以直观区分含有目标回波的信号和纯海杂波信号。当差值曲线中出现明显的误差尖峰时, 可判定目标信号存在。尽管误差峰值判断方法直观有效, 但其依赖人工观察, 效率较低。因此, 定义均方根误差 (root mean square error, RMSE) 量化误差以提高检测效率。比较不同距离门的 RMSE 值, 发现含有目标回波的距离门的 RMSE 值较大。基于此差异可以确定一个阈值用于区分目标门与杂波门。检测流程如图 3 所示。

基于 AWE-NRBO-BiLSTM 的海面微弱信号检测具体

步骤如下。

1) 选择雷达数据的若干个连续点, 以 2 : 1 划分训练集与测试集, 通过 C-C 法确定嵌入维度与延迟时间, 嵌入维度 m 为 3, 延迟函数 τ 为 11, 进行相空间重构。

2) 对数据进行归一化处理, 输入 BiLSTM 模型中进行单步预测。

3) 初始化 NRBO 参数, 确定种群规模为 30, 设置最大迭代次数 50, 以模型预测结果的 RMSE 为适应度函数值。

4) 根据 NRSR 规则探索新解, 使用陷阱规避操作避免陷入局部最优。对于第 t 次迭代中的第 n 个超参数组, 应用 NRSR 规则探索个体位置, 新位置表达式为:

$$x_n^{t+1} = r_1 [r_1 X1_n^t + (1 - r_2) X2_n^t] + (1 - r_2) X3_n^t \quad (11)$$

式中: x_n^{t+1} 为应用 NRSR 规则搜索的新位置; $X1_n^t$ 、 $X2_n^t$ 、 $X3_n^t$ 分别为由当前位置更新得到的 3 个位置; t 和 n 分别为迭代次数和个体序号; r_1 和 r_2 分别代表 0~1 之间的随机数。引入的 TAO 通过将最佳位置 x_b 和 NRSR 得到的矢量位置 x_n^{t+1} 组合, 生成具有增强质的解决方案 x_{TAO}^t 。通过比较随机数 $rand$ 和 DF 的值, 产生新的值, 其中随机数 $rand$ 取 0~1 之间的值, DF 表示控制 NRBO 性能的决定因素, 其值通常为 0.6。产生新的值为:

$$\begin{cases} x_n^{t+1} = x_{TAO}^t, & rand < DF \\ x_n^{t+1} = x_n^{t+1}, & rand \geq DF \end{cases} \quad (12)$$

当随机数 $\mu_1 < 0.5$ 时, 得到增强质为:

$$x_{TAO}^t = x_n^{t+1} + \theta_1(\mu_1 x_b - \mu_2 x_n^t) + \theta_2 \delta(\mu_1 Mean(x') - \mu_2 x_n^t) \quad (13)$$

当随机数 $\mu_1 \geq 0.5$ 时, 得到增强质为:

$$x_{TAO}^t = x_b + \theta_1(\mu_1 x_b - \mu_2 x_n^t) + \theta_2 \delta \times (\mu_1 Mean(x') - \mu_2 x_n^t) \quad (14)$$

式中: θ_1 和 θ_2 分别是 (-1, 1) 和 (-0.5, 0.5) 之间的随机数; $Mean$ 函数表示取均值。

5) 重复上述步骤, 直到达到最大迭代次数或适应度值收敛为止。根据所得超参数初始化 BiLSTM 模型, 以 AWE 作为损失函数训练模型, 得到预测数据。对预测数据进行反归一化, 计算预测结果与原始信号的幅度相对差值得到预测误差, 根据预测误差判断微弱目标信号是否存在。

6) 计算各个距离门的 RMSE 值, 确定目标门的 RMSE 最小值与杂波门的 RMSE 最大值, 其间隔即为检测阈值可选区间。

3 实验与分析

为验证所提 AWE-NRBO-BiLSTM 预测模型的可行性




图 3 检测流程

Fig. 3 Detection flow chart

与有效性,本文设计 3 个实验。实验 1 使用 Lorenz 混沌背景噪声 $c(n)$,并将瞬态小信号叠加到 $c(n)$ 上,得到观测序列信号 $x(n)$,使用所提模型对观测信号进行预测,探究其检测精度与检测阈值;实验 2 使用加拿大 IPIX 数据集的实测数据,分析所提模型的实际检测效果;实验 3 使用国内的烟台对海数据集,使用 AWE-NRBO-BiLSTM 模型进行预测,分析模型的预测效果,检验模型的鲁棒性。

3.1 Lorenz 混沌背景噪声下微弱信号检测仿真实验

Lorenz 系统是一个经典的三维混沌系统,其数学描述如式(15)所示。

$$\begin{aligned} \dot{x} &= \sigma(y - x) \\ \dot{y} &= -xz + rx - y \\ \dot{z} &= xy - bz \end{aligned} \quad (15)$$

式中:系统参数 $\sigma = 16$ 、 $r = 45.92$ 、 $b = 4$,系统的初始值 $x = 1$ 、 $y = 0$ 、 $z = 0.1$,采用步长为 0.01 的四阶龙格库塔(Runge-Kutta)法求解方程。舍弃前 3 000 点确保系统完全进入混沌状态后,连续取 6 000 样本点,以 2:1 的比例切分训练集和测试集,即使用前 4 000 样本点训练预测模型,后 2 000 样本点作为测试样本检验模型预测能力。在测试集 $c(n)$ 的第 150 点周围叠加幅值为 0.05 的微弱

瞬时信号 $x(n)$,得到叠加信号 $x(n)$,其信噪比(SNR)为 -67 dB。将其输入预测模型,以均方误差(mean squared error, MSE)作为损失函数,得到单步预测结果如图 4 所示,红色点为真实值,蓝色线为预测值。




图 4 单步预测结果

Fig. 4 Single-step prediction of the outcome

经过实验统计分析,当 LSTM 隐藏层为 1 时即可有效满足混沌时间序列的任务需求,并且最大程度降低计算成本。将迭代次数、学习率、隐藏层单元数、batch 数等超参数展成超参数空间,使用 NRBO 算法在其中寻找局部最优解。经过 NRBO 搜索优化参数,得到最优迭代次数为 100,学习率为 0.003,隐藏层单元为 64,batch 为 32。图 5 为预测误差,可以看到,在 150 点附近出现两条明显的误差尖峰,第 1 条尖峰是目标信号产生,第 2 条尖峰是由目标信号经过相空间重构的时间延迟产生,由此可以判断该区域内有微弱瞬时信号的存在。




图 5 预测误差

Fig. 5 Prediction error

神经网络可以对混沌系统进行拟合,实现短时预测,因此整体预测误差很小,而微弱信号属于叠加在混沌系统上的外来信号,无法被神经网络检测出,因而在该处会出现较大误差。传统的损失函数,如 MSE 等,直接计算预测值与真实值的相对误差,并以此为损失计算梯度下降,此方法对所有误差一视同仁,当微弱目标的误差较小时,容易被忽略。因此,提出以 AWE 损失代替原本的 MSE 损失,提高检测精度。

由 AWE 公式可知, 使用 AWE 作为损失函数时, 当预测误差较小时权重约为一, 此时与标准 MSE 类似, 不改变权重。当预测误差较大时, 权重增大, 使得模型更关注这些点, 增强模型训练效果, 提高检测能力。相比 MSE 等传统损失函数, AWE 损失函数含有超参数 α 以控制加权强度, 通过 NRBO 优化算法得到其最佳值。当 $\alpha=0.7$ 时, 使用 BiLSTM 模型, 与传统损失函数对比结果如表 1 所示。

表 1 不同损失函数的模型性能对比

Table 1 Comparison of the performance of different loss functions in model training

损失函数	AWE	MSE	MAE	Huber Loss
SNR/dB	-74.30	-67.12	-65.30	-69.61
RMSE	0.0001	0.0050	0.0050	0.0010

表 1 中 SNR 为微弱信号与杂波比值的对数, RMSE 为检测误差, MAE 为平均绝对误差损失, Huber Loss 是改进的 MAE 损失函数, 它结合了 MSE 和平均 MAE 的优点, 在误差较小的时候类似 MSE, 而在误差较大的时候则类似 MAE。其公式如下:

$$L_\delta(y, \hat{y}) = \begin{cases} \frac{1}{2}(y - \hat{y})^2, & |y - \hat{y}| \leq \delta \\ \delta \cdot \left(|y - \hat{y}| - \frac{1}{2}\delta \right), & |y - \hat{y}| > \delta \end{cases} \quad (16)$$

式中: y 是真实值; \hat{y} 是预测值; δ 是一个超参数, 用于控制损失函数的平滑过渡, $<\delta$ 的误差使用平方损失, $>\delta$ 的误差则使用线性损失。

使用 AWE 作为损失函数, 在测试集 $c(n)$ 的第 150 点周围叠加幅值更小的微弱瞬时信号 $x(n)$, 其信杂比达到-74 dB, 仍能检测出微弱信号。从表 1 中可以看出, 使用 AWE 作为损失函数, 能适应更低的信杂比条件, 检测精度更高, 可以在更强的噪声背景环境中检测到微弱目标信号。

与 SVM、RBF 神经网络等^[19]混沌序列模型性能对比, 结果如表 2 所示。相对于传统的支持向量机以及 RBF 神经网络, 所提模型可以在最低的信杂比环境下以较低的误差检测出目标信号, 证明其对混沌系统的预测效果与微弱信号的检测能力都更高。本实验验证了所提模型对于微弱信号的检测能力。

3.2 IPIX 海杂波背景下微弱信号检测

为验证基于 AWE-NRBO-BiLSTM 的微弱信号检测方法的实用性, 使用实测的 IPIX 海杂波数据^[20]进行试验。本文使用 IPIX 雷达的达特茅斯 1993 年数据集。该数据是在加拿大东海岸使用 IPIX 雷达从新斯科舍省达特茅斯附近的悬崖顶收集的, 雷达发射频率为 9.3 GHz, 脉冲


重复频率为 2 000 Hz, 采样距离间隔为 15 m, 极化方式为 HH、VV、HV、VH 4 种, 待测目标是直径 1 m 的铝丝包裹的小球。

表 2 混沌序列模型性能对比

Table 2 Comparison of the performance of chaotic sequence models

模型	本文	LSSVM	SVM	RBF-NN
SNR/dB	-74.30	-62.82	-54.60	-30.20
RMSE	0.0001	0.0220	0.0490	0.0580

使用 IPIX 数据集的 HH 极化模式的第 17、26、54 组数据, 其包含了不同海况、信杂比情况, 具有代表性。采用 C-C 法确定嵌入维度 m 与延迟时间 τ , 计算得到嵌入维度 m 为 3, 延迟函数 τ 为 11, 由此确定时间步 (Timesteps) 为 m 与 τ 的乘积。根据 NRBO 优化算法确定最优迭代次数为 250, 学习率为 0.001, 隐藏层单元为 74, batch 为 32。训练样本设置为 5 000 个, 测试样本设置为 2 500 个。实验结果如图 6 所示。






图 6 海杂波与含有目标回波信号的预测误差

Fig. 6 Prediction error of sea clutter and target echo signals

雷达的距离门是指测量的距离单位, IPIX 数据库中不同的数据集测量的距离范围不同, 但均被划分为 14 个距离门。图 6 中的“纯杂波”子图指的是无目标的距离门, 表示只检测到海杂波的区域; 而“含目标回波”子图指的是主目标距离门, 即目标所在的距离范围。以 IPIX 数据库的#17 数据集为例, 该数据集共有 14 个距离门, 其中 9 号距离门为主目标距离门, 8、10、11 号距离门为次目标距离门, 其他距离门则为纯杂波距离门。主目标距离门代表目标的实际位置, 次目标距离门是雷达回波可能受到目标影响的距离, 而杂波门则表示仅检测到海杂波的区域。

从图 6 可以看出, 在第 17、26 和 54 组的条件下, 无目标距离门与主目标距离门之间的预测误差存在明显差异。在无目标距离门中, 预测误差未出现尖峰, 而在主目标距离门中, 则能清晰地看到明显的尖峰, 表明存在微弱目标信号。通过图 6 可以验证海杂波数据中确实存在微弱信号, 尽管这一现象在图形上较为直观, 但需要依赖人

工观察和主观判断, 无法满足实际工程中对雷达自动化处理的需求, 需要一种客观的指标来量化目标与杂波之间的差异, 因此选用了 RMSE 作为衡量指标。表 3 为第 17 组数据的归一化 RMSE。

表 3 第 17 组数据所有距离门的 RMSE

Table 3 #17 data RMSE for all distance gates

距离门	归一化 RMSE
1	0.000 3
2	0.022 8
3	0.049 6
4	0.004 4
5	0.000 0
6	0.080 5
7	0.006 8
8	0.564 4
9	1.000 0
10	0.735 5
11	0.239 3
12	0.008 2
13	0.026 1
14	0.013 9

从表 3 可以看出, 模型在杂波门的预测效果最佳, RMSE 值较小。这是因为海杂波作为一种混沌系统, 具有较强的时序规律性, 适合通过神经网络进行短时预测。而模型在目标门的预测效果较差, RMSE 值较大, 原因在于目标信号是叠加信号, 不存在周期规律。为利于观察, 由表 3 的数据可以得到折线图如图 7 所示。




图 7 第 17 组数据所有距离门 RMSE

Fig. 7 RMSE of all distances for group 17 data

考虑到 RMSE 反映了模型对混沌系统拟合的程度, 但雷达系统中的问题本质上是二分类问题——即区分有目标与无目标, 所以更应关注的是目标门与杂波门之间的差异性特征。图 7 中, 含有目标信号的回波用红色点标出, 纯杂波信号用蓝色点标出, 虚线区域为可选阈值空间。可以看出主目标距离门 RMSE 值最大, 显著高于杂波门, 而次目标距离门和杂波门的差值相对较小, 因此影响目标检测的关键因素是目标距离门的最小值与杂波距离门最大值之间的差异。由于 RMSE 值较小, 定义目标

门 RMSE 的最小值与杂波门 RMSE 的最大值之比作为衡量指标,称为“RMSE 最值比”,如式(17)所示。

$$ExRatio = \frac{RMSE_{target}^{\min}}{RMSE_{clutter}^{\max}} \quad (17)$$

式中: $ExRatio$ 表示 RMSE 最值比; $RMSE_{target}^{\min}$ 表示目标门 RMSE 最小值; $RMSE_{clutter}^{\max}$ 表示杂波门 RMSE 最大值。RMSE 最值比可以量化目标与杂波之间的区分度,其值越大,表明微弱信号与海杂波的区分度越高,模型的容错能力和检测效果也越好。比较几种 LSTM 方法的特点如表 4 所示。

表 4 不同检测方法比较

Table 4 Comparison of various detection methods

#17	ExRatio	预处理(去噪)	迭代次数
LSTM ^[8]	1.60	否	10 000
WOA-LSTM ^[21]	2.32	是	300
本文	2.97	否	200

表 4 中, WOA-LSTM 方法在预测前经过小波去噪处理,计算成本比其他方法更高。而本文所提方法 RMSE 最值比最大,使用的迭代次数最少,对于目标信号的区分效果和运行效率都较高。传统 LSTM 方法无法直接从时域检测出第 54 组的微弱信号,需要结合频域共同分析,而所提方法可以直接从时域检测到微弱信号,且训练模型使用的迭代次数显著降低,从 10 000 次降低至 200 次,需要的训练集长度更少,从 10 000 点降低至 5 000 点。相较 LSTM 与 WOA-LSTM,所提方法的检测能力分别提高了 78% 与 28%。

实验证明,结合相空间重构,所提 AWE-NRBO-BiLSTM 的微弱信号检测方法在不同海况下均能检测到微弱信号。本方法显著减少了训练时长,降低了对信号长度的依赖性,降低了信号的阈值,提高了模型效率与精度。

3.3 烟台海杂波背景下微弱信号检测

为衡量模型对噪声环境、输入数据质量变化等扰动的耐受能力,使用国内烟台对海数据集进行实验,检验模型在复杂环境下的鲁棒性。该数据集来源于海军航空大学的“雷达对海探测数据共享计划”^[22]。采用数据集中最新的 20221112140039_stare 数据。雷达型号为天奥 SPPR50P,极化方式为 HH,发射的组合脉冲在时间上依次为单脉冲信号 T1、LFM 脉冲信号 T2 和 LFM 脉冲信号 T3,整体重复频率为 2 000 Hz,目标为两个钢制灯浮漂,分别在 2.97、3.19 nmi (1 nmi = 1 852 m) 处,有效浪高 1.8 m,海况等级 4 级。本文采用 T1 单脉冲信号,检测目标为浮标 1,回波距离门共有 950 个,目标距离门在 442~454 处,信号长度为 131 000,总观测时间为 65.5 s。杂波门和目标门的预测结果误差 RMSE 如图 8 所示。

图 8 中,明显观测到目标门在 1 800 样本点附近有误




图 8 烟台数据集预测误差

Fig. 8 Prediction error of Yantai dataset

差峰出现,其峰值是杂波门该处峰值的约 4 倍,可以判断该处有微弱信号存在。由于该数据集的距离门较多,为与实验二的距离门个数保持一致,采用等间隔抽样的方式从 950 个距离门中选择 4 个目标距离门与 10 个纯海杂波距离门进行分析;以 100 个时间单位为间距,等间隔的取该数据集的 10 个纯杂波距离门,并以 2 个时间单位为间隔,取 4 个目标距离门,得到预测结果误差的 RMSE。由于该数据初值较大,得到的 RMSE 相对更大,为了便于观察,对 14 个 RMSE 值做归一化处理,结果如表 5 所示。

表 5 烟台数据集部分距离门归一化 RMSE

Table 5 Partial distance gate normalized

RMSE in Yantai dataset

距离门	归一化 RMSE
1	0.251 8
101	0.208 5
201	0.398 2
301	0.075 6
401	0.291 1
445	0.838 8
447	1.000 0
449	0.681 5
451	0.551 6
501	0.111 9
601	0.078 9
701	0.010 7
801	0.000 0
901	0.006 6

由表 5 数据可以得到折线图如图 9 所示。图 9 中目标距离门的 RMSE 显著大于杂波门的 RMSE, 目标门的 RMSE 最小值为 0.551 6, 杂波门的 RMSE 最大值为 0.398 2, 最值比为 1.39, 虚线之间的范围为可选阈值门限, 显然可选阈值门限范围充裕。阈值门限设置在 0.45~0.55 即可有效区分目标门与杂波门。




图 9 烟台数据集部分距离门归一化 RMSE

Fig. 9 The RMSE of the distance normalization of the Yantai dataset

综合以上 3 个实验结果可知, 所提方法在不同海情和海域条件下, 均能有效从海杂波背景噪声中检测出微弱目标信号。模型在面对数据中的噪声、不完全信息及小的扰动时, 依然能够保持良好的表现, 展示了其较强的鲁棒性。

4 结 论

针对强混沌背景噪声下传统方法难以检测微弱目标信号的问题, 本文提出了一种基于 AWE-NRBO-BiLSTM 的海面微弱信号检测方法, 借助相空间重构理论得到有效的数据输入形式, 使用改进牛顿-拉夫逊算法获得模型最优超参数, 以自适应权重误差作为损失函数, 通过 BiLSTM 模型单步预测, 结合预测误差, 实现了在不同海杂波背景下对微弱信号的有效检测。通过引入 Lorenz 系统证明了模型的基本检测能力, 使用 IPIX 和烟台对海数据集, 检验了所提方法在不同海域、海情的检测能力。相比传统 LSTM 与改进 LSTM 模型, 检测效果提高 28% 以上。

后续研究可以考虑结合注意力机制, 帮助模型更好地聚焦于重要的信号特征, 忽略噪声和无关的信息。结合多种深度学习模型, 形成混合架构, 增强模型的鲁棒性。结合信号处理方法, 考虑对误差做频域、时频域、极化域等多域分析, 从而进一步提升模型的精度与泛化性。

参考文献

[1] 许述文, 白晓惠, 郭子薰, 等. 海杂波背景下雷达目标

特征检测方法的现状与展望 [J]. 雷达学报, 2020, 9(4):684-714.

XU SH W, BAI X H, GUO Z X, et al. Status and prospects of feature-based detection methods for floating targets on the sea surface [J]. Journal of Radars, 2020, 9(4): 684-714.

[2] 郭子薰. 海面小目标高维特征空间学习检测方法研究 [D]. 西安: 西安电子科技大学, 2022.

GUO Z X. Research on high-dimensional feature space learning detection methods for small targets on the sea surface [D]. Xi'an: Xidian University, 2022.

[3] 丁昊, 董云龙, 刘宁波, 等. 海杂波特性认知研究进展与展望 [J]. 雷达学报, 2016, 5(5): 499-516.

DING H, DONG Y L, LIU N B, et al. Research progress and prospects of sea clutter characteristics cognition [J]. Journal of Radars, 2016, 5 (5): 499-516.

[4] HAYKIN S, XIAO B L. Detection of signals in chaos [J]. Proceedings of the IEEE, 1995, 8 (1):95-122.

[5] XING H Y, JIN T L. Weak signal estimation in chaotic clutter using wavelet analysis and symmetric LS-SVM regression [J]. Acta Physica Sinica, 2010, 59: 140-146.

[6] YIN Z, ZHU J, ZHANG X, et al. Forecast customer flow using long short-term memory networks [C]. 2017 International Conference on Security, Pattern Analysis, and Cybernetics (SPAC), 2017: 61-66.

[7] SHI H, XU M, LI R. Deep learning for household load forecasting-a novel pooling deep RNN [J]. IEEE Transactions on Smart Grid, 2018, 9(5):5271-5280.

[8] YAN Y, XING H Y. A sea clutter detection method based on LSTM error frequency domain conversion [J]. Alexandria Engineering Journal, 2022, 61 (1): 883-891.

[9] DE J R J, HEILIGERS M J C, ROSENBERG L. Discrimination of small targets in sea clutter using a hybrid CNN-LSTM network [C]. 2023 IEEE International Radar Conference (RADAR), 2023: 1-6.

[10] ABDELKADER A G, ZAINELDIN H, SAAFAN M M. Optimizing wind power forecasting with RNN-LSTM models through grid search cross-validation [J]. Sustainable Computing: Informatics and Systems, 2025, 45: 1.

[11] 叶如, 行鸿彦, 周星. 基于优化长短时记忆网络的海面微弱目标检测 [J]. 探测与控制学报, 2024,

- 46(5) : 57-63.
- YE R, XING H Y, ZHOU X. Sea surface weak target detection based on optimized long short-term memory network [J]. Journal of Detection and Control, 2024, 46(5) : 57-63.
- [12] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1) : 22-34.
- [13] CHEN J, LIU J, MA X, et al. Fast two-dimensional positioning method of crab pulsar based on multiple optimization algorithms [J]. Research in Astronomy and Astrophysics, 2024, 24(10) : 94-105.
- [14] 马永杰, 云文霞. 遗传算法研究进展 [J]. 计算机应用研究, 2012, 29(4) : 1201-1206, 1210.
MA Y J, YUN W X. Research progress of genetic algorithms [J]. Computer Applications and Research, 2012, 29(4) : 1201-1206, 1210.
- [15] 梁欣怡, 行鸿彦, 侯天浩. 基于自监督特征增强的 CNN-BiLSTM 网络入侵检测方法 [J]. 电子测量与仪器学报, 2022, 36(10) : 65-73.
LIANG X Y, XING H Y, HOU T H. Intrusion detection method based on self-supervised feature enhancement in CNN-BiLSTM network [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36 (10) : 65-73.
- [16] LI Z, CAO L, SHAO W X, et al. Detection of small target in sea clutter based on spatio-temporal chaos analysis [J]. Optics and Precision Engineering, 2018, 26(1) : 193-199.
- [17] RAVICHANDRAN S, MANOHARAN P, PRADEEP J. Newton-raphson-based optimizer: A new population-based metaheuristic algorithm for continuous optimization problems [J]. Engineering Applications of Artificial Intelligence, 2024, 128: 107532.
- [18] 黎宇杰, 史国勇, 廖毅, 等. 基于 NRBO-SVM 模型的月径流预测研究 [J]. 水力发电, 2025, 51(1) : 16-21.
LI Y J, SHI G Y, LIAO Y, et al. Research on monthly runoff prediction based on NRBO-SVM model [J]. Hydroelectric Power, 2025, 51(1) : 16-21.
- [19] 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.
- [20] 白晓惠. 海杂波中低速小目标的特征检测与分类方法 [D]. 西安: 西安电子科技大学, 2024.
- BAI X H. Feature detection and classification methods for low-speed small targets in sea clutter [D]. Xi'an Jiaotong University, 2024.
- [21] 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 S, SHI Y S, 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.
- [22] 关键, 刘宁波, 王国庆, 等. 雷达对海探测试验与目标特性数据获取——海上目标双极化多海况散射特性数据集 [J]. 雷达学报, 2023, 12(2) : 456-469.
GUAN J, LIU N B, WANG G Q, et al. Radar sea detection experiments and target characteristic data acquisition: A dual-polarization multi-sea-state scattering characteristic dataset of maritime targets [J]. Journal of Radars, 2023, 12(2) : 456-469.

作者简介



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.



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 supervisor for Ph. D. student in Nanjing University of Information Science & Technology. His main research interests include weak

signal detection, bio-medical signal collection and processing, and design of intelligent electronic measurement technology and instrument.



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 includes weak signal detection.



杭陈雨, 2024 年于南京信息工程大学获得学士学位, 现为南京信息工程大学研究生, 主要研究方向为雷雨预测与信号处理。

E-mail: 13601575400@163.com

Hang Chenyu received his B. Sc. degree from Nanjing University of Information Science and Technology in 2024. Now he is a M. Sc. candidate at the same university. His main research interests include thunderstorm prediction and signal processing.