引用格式:唐建军,梁浩,朱张勤,等. 海杂波背景下漂浮小目标检测新算法[J]. 电光与控制,2021,28(5):51-55, 84. TANG J J, LIANG H, ZHU Z Q, et al. A new algorithm for floating small target detection under sea clutter background[J]. Electronics Optics & Control, 2021, 28(5):51-55, 84.

海杂波背景下漂浮小目标检测新算法

唐建军, 梁 浩, 朱张勤, 金 林
(南京电子技术研究所,南京 210039)

摘 要: 针对海杂波背景下漂浮小目标检测问题,提出一种海杂波背景下漂浮小目标检测新算法。利用互补自适应噪声集合经验模式分解-鲁棒性独立主成分分析与Savitzky-Golay滤波算法(EEMDCAN-Robust ICA & SG)联合去噪算法处理海面回波信号,对重构信号用改进蝙蝠算法优化KELM模型做混沌预测。实验结果表明:新算法在不破坏海杂波混沌特性的前提下,极大地抑制了海杂波。在同等条件下,与传统混沌预测算法相比,训练时间短、预测精度高。新算法的检测性能稳定,低信杂比下的检测性能显著优于传统算法,证明新算法能快速实现对漂浮小目标的有效检测。

关键词: 目标检测; 海杂波; 漂浮小目标; EEMDCAN; Robust ICA; 改进蝙蝠算法; KELM
中图分类号: TN959.72 **文献标志码**: A **doi**:10.3969/j.issn.1671-637X.2021.05.012

A New Algorithm for Floating Small Target Detection Under Sea Clutter Background

TANG Jianjun, LIANG Hao, ZHU Zhangqin, JIN Lin
(Nanjing Institute of Electronic Technology, Nanjing 210039, China)

Abstract: Aiming at the problem of floating small target detection under sea clutter background, a new floating small target detection algorithm, EEMDCAN-Robust ICA & SG, is proposed. The denoising algorithm combines EEMDCAN, Robust ICA with Savitzky-Golay filtering algorithm to process sea echo signal, and the improved bat algorithm is used to optimize KELM model for chaotic prediction of reconstructed signal. The experimental results show that: 1) The new algorithm greatly suppresses the sea clutter without destroying the chaotic characteristics of the sea clutter; 2) Under the same conditions, the training time is shorter and the prediction accuracy is higher compared with that of the traditional chaos prediction algorithms; and 3) The detection performance of the new algorithm is stable, and the detection performance under low signal to clutter ratio is significantly superior to that of the traditional algorithm. It has been proved that the new algorithm can detect small floating targets quickly and effectively.

Key words: target detection; sea clutter; floating small target; EEMDCAN; Robust ICA; improved bat algorithm; KELM

0 引言

海杂波背景下小船、浮标、浮冰等漂浮小目标是研究的重点与难点,极大地限制了海面搜索雷达目标检测的能力,引发众多学者开展小目标检测方面的研究。

1995年,HAYKIN利用海杂波的混沌特性结合BP网络进行目标检测,但是检测效率低、训练时间长,难以加入到工程实际中。HUANG等[1]于1998年首次提出一种新的时频分析算法——经验模式分解(EMD),从此,大量学者开始关注和广泛应用该算法。随着研究的不断深入,EMD结合神经网络进行混沌预测算法受到学者们的广泛关注。早期混沌预测中,神经网络训练时间长、预测精度不高,因此,寻找性能更好的神经网络模型与模型参数优化算法显得至关重要。

本文提出了一种海杂波背景下漂浮小目标检测的新算法,其核心思想是,利用互补自适应噪声集合经验模式分解(EEMDCAN)结合鲁棒性独立成分分析算法(Robust ICA)与SG(Savitzky-Golay)滤波算法进行海杂波抑制,利用改进蝙蝠(BA)算法优化KELM模型对雷

收稿日期:2020-05-13 **修回日期**:2021-03-30
作者简介:唐建军(1996—),男,四川攀枝花人,硕士生,研究方向为海杂波小目标检测技术研究。

达回波信号进行预测,根据预测结果判断其是否含有目标。

1 相关算法理论

1.1 互补自适应噪声集合经验模式分解

为避免模态混叠,集合经验模式分解(EEMD)[2]、互补集合经验模式分解(CEEMD)[3]、基于自适应噪声的集合经验模式分解(CEEMDAN)[4]陆续被学者提出。其中,CEEMDAN 极大地降低了计算量和信号重构误差,虚假分量减少。因集合平均次数的限制,虽然重构误差已经很小,但每个 *imf* 分量分解完成后,仍残余噪声。EEMDCAN[5]是对 CEEMDAN 的改进,在每层分解过程中,根据 CEEMD 的处理思想,成对加入正负噪声,其他过程不变。EEMDCAN 具体算法步骤如下。

1) 加入成对的正负噪声求解第一阶 *imf* 分量,对 $s(t)+(-1)^q a_0 n^i(t)$ 做 EMD 分解,即

$$s(t)+(-1)^q a_0 n^i(t)=imf_1^i(t)+r_1^i(t) \tag{1}$$

式中:$s(t)$ 为待分析的信号;$(-1)^q$ 为加入的噪声正负,q 表示添加噪声信号时是加上正噪声还是负噪声,$q=1,2$;i 为分离出的分量序号,$i=1,2,\cdots,M/2$,$M/2$ 为加入噪声对数;a_0 为噪声幅度;$n^i(t)$ 为高斯白噪声;平均 M 个 imf_1^i,$imf_1(t)=\frac{1}{M}\sum_{i=1}^{M} imf_1^i(t)=s(t)-\frac{1}{M}\sum_{i=1}^{M} r_1^i(t)$。

2) 求解剩余分量

$$r_1(t)=s(t)-imf_1(t)=\frac{1}{M}\sum_{i=1}^{M} r_1^i(t) \tag{2}$$

添加EMD分解的噪声分量得 $r_1(t)+(-1)^q a_1 E_1(n^i(t))$,做EMD分解 $r_1(t)+(-1)^q a_1 E_1(n^i(t))=imf_2^i(t)+r_2^i(t)$,平均 M 个 imf_2^i,$imf_2(t)=\frac{1}{M}\sum_{i=1}^{M} imf_2^i(t)=r_1(t)-\frac{1}{M}\sum_{i=1}^{M} r_2^i(t)$,即剩余分量是 $r_2(t)=r_1(t)-imf_2(t)=\frac{1}{M}\sum_{i=1}^{M} r_2^i(t)$。

3) 在求得剩余分量中加入正负噪声分量 $r_k(t)+(-1)^q a_k E_k(n^i(t))(k=2,3,\cdots)$,再做 EMD 分解得 $r_k(t)+(-1)^q a_k E_k(n^i(t))=imf_{k+1}^i(t)+r_{k+1}^i(t)$,平均 M 个 imf_k^i,$imf_{k+1}(t)=\frac{1}{M}\sum_{i-1}^{M} imf_{k+1}^i(t)=r_k(t)-\frac{1}{M}\cdot\sum_{i=1}^{M} r_{k+1}^i(t)$,即剩余分量 $r_{k+1}(t)=r_k(t)-imf_{k+1}(t)=\frac{1}{M}\cdot\sum_{i=1}^{M} r_{k+1}^i(t)$,且因 M 次平均,使得 $(-1)^q a_k E_k(n^i(t))$,$k=2,3,\cdots$,互相抵消。

4) 重复步骤3),直到分解出剩余项 $R(t)$。

重构误差就是各 *imf* 分量残留噪声之和,重构误差虽足够小,但并不是各 *imf* 中残余噪声都小到可忽略不计,若集合平均次数不足,残余噪声更明显。更多噪声次数需要提高集合平均次数,分解的总迭代次数也会增加,运算量变大。如表1所示,算法计算量并没有增加,且文献[2]已详细论证 EEMDCAN 的 *imf* 残余噪声明显小于 CEEMDAN。

表1 算法总迭代次数对比

Table 1 Comparison of total iterations of the algorithm

	第1次迭代	第2次迭代	第3次迭代
添加单次噪声次数	10	40	400
CEEMDAN 总迭代数	2440	11783	82215
添加正负噪声对数	5	20	200
EEMDCAN 总迭代数	1755	8108	74927

1.2 基于核函数的极限学习机(KELM)

ELM[6]输入权值随机初始化,隐含层节点确定难度大,容易出现过拟合,HUANG 等[7]在 ELM 中引入核函数,提出基于核函数的极限学习机(KELM),提高了 ELM 稳健性与泛化性能,理论推导参考相应文献,介绍省略。

2 海杂波背景下漂浮小目标检测新算法

2.1 EEMDCAN-Robust ICA & SG 滤波联合算法

噪声集中在低阶 *imf* 分量中,传统 EMD 去噪是直接滤除或阈值去噪,会丢失 *imf* 分量中部分有效信号,且效果不佳,原因是未考虑其物理意义。低信噪比下,阈值去噪会破坏信号完整性,去噪效果更差。

EEMDCAN-Robust ICA & SG 算法循环去噪,只有保证去噪重组 *IMF* 分量的互相关系数曲线和原曲线趋势大体一致,才能最大程度地抑制海杂波,不破坏信号的混沌特性和目标信息,算法步骤如下。

1) 对信号做预处理(零均值化,幅值归一化)后,EEMDCAN 分解信号得 *imf* 分量与剩余项。

2) 计算各 *imf* 分量排列组合熵[8](m 与 τ 为计算排列组合熵时的参数,m 取4,τ 取1),再计算相邻 *imf* 分量的熵差,将熵差小于0.1的 *imf* 分量合并,得到重组分量 IMF_j。

3) 计算 IMF_j 分量与原信号的互相关系数,即

$$R(x(t),IMF_j(t))=\frac{\sum_{t=1}^{N}[x(t)-\bar{x}][IMF_j(t)-IMF_j']}{\sqrt{\sum_{t=1}^{N}[x(t)-\bar{x}]^2}\cdot\sqrt{\sum_{t=1}^{N}[IMF_j(t)-IMF_j']^2}} \tag{3}$$

式中:N 表示信号序列长度;$\bar{x}=\frac{1}{N}\sum_{t=1}^{N} x(t)$;$IMF_j'=\frac{1}{N}\sum_{t=1}^{N} IMF_j(t)$。

4）计算相关系数曲线，找出除一阶 *IMF* 的互相关系数外，首个互相关系数极小值点所对应分量是 IMF_k，则杂波 *IMF* 分量和目标分量的分界点就是 IMF_{k+1}。

5）前 k 个 *IMF* 分量作为 Robust ICA[9-10] 输入信号，进行去噪，对剩余重组 *IMF* 分量做 SG 滤波。

6）计算去噪后的 *IMF* 分量与原信号的相关系数曲线，排除一阶 *IMF* 的互相关系数外，首个互相关系数极小值点所对应分量是 IMF_u，如果 $k' \neq u$，则将 u 的值赋给 k'（u 为首次得到的局部最小点的阶次，k'为去噪后经再次计算分析得到的局部极小点的阶次），且返回步骤 5）；否则，重构信号。

2.2　优化 KELM 混沌预测算法

YANG[11] 受蝙蝠行为启发提出蝙蝠（BA）算法，该算法性能显著优于 PSO 和 GA 等算法。因 BA 算法每次迭代均会随机扰动已知解，避免局部最优，寻找全局最优，KELM 的惩罚系数 C 和核参数 σ 会影响模型性能，所以用其寻优。算法如下所述。

每只蝙蝠位置为 $X_i(i=1,2,\cdots,n)$，速度为 V_i，且发出信号参数（响度为 A_i、脉冲速率为 r_i、脉冲频率为 f_i）。与 PSO 算法相似，BA 算法首先产生初始种群，不断更新每只蝙蝠位置 X_i 与速度 V_i，即

$$f_i = f_{\min} + (f_{\max} - f_{\min})\boldsymbol{\beta} \quad \boldsymbol{\beta} \in [0,1] \tag{4}$$

$$V_i^t = V_i^{t-1} + (X_i^t - X^*) f_i \tag{5}$$

$$X_i^t = X_i^{t-1} + V_i^t \tag{6}$$

式中：$\boldsymbol{\beta}$ 为随机向量；X^* 为当前全局最佳位置；最小、最大频率分别为 $f_{\min}$、$f_{\max}$。与粒子群不同，局部搜索被引入 BA 算法，若随机数 $r > r_i$，从最佳解集中选一个解，在该最佳解附近得到一局部解，即

$$X_{\text{new}} = X_{\text{old}} + \varepsilon A^t \quad \varepsilon \in [-1,1] \tag{7}$$

否则，继续随意飞行更新一个解。式中，ε 为随机数。新一代所有蝙蝠的平均响度为 $A^t = \langle A_i^t \rangle$。如果 $r < A_i$ & $f(X_i) < f(X^*)$，则接受这个新解，同时更新 A_i、r_i，因为发现猎物后会影响蝙蝠信号的响度与脉冲速率

$$\begin{cases} A_i^t = \alpha A_i^{t-1} \\ r_i^t = r_i^0 [1 - \mathrm{e}^{-\gamma t}] \end{cases} \tag{8}$$

式中，α、γ 为常量。排列蝙蝠每次迭代后的位置，得到当前最好的 X^*，直至寻到全局最优位置。

为避免 BA 算法陷入局部最优，提高寻优能力，以优化 BA 算法。引入随机性较好的莱维飞行，引入该思想更新蝙蝠位置，可避免算法陷入局部最优问题

$$Levy(\omega) - u = t^{-\omega} \quad 1 < \omega \leqslant 3 \tag{9}$$

$$X_t = X_{t-1} + V_i^t + \varphi \oplus Levy(\omega) \quad \varphi \in [-1,1] \tag{10}$$

式中，ω 和 φ 为调参部分参数。为使全局与局部搜索能力处于平稳状态，动态更新 α 值，因 α 类似于模拟退火算法冷却进程表中的冷却因素，若太小，则算法容易陷入局部搜索；若太大，则距离过远。更新 α 为 $\alpha_{\text{new}} = (1/2t)^{1/t}\alpha_{\text{old}}$。

2.3　漂浮小目标检测新算法

受目标检测实时性的要求，预测模型不采用常规多个预测模型分别预测重组 *IMF* 分量，再重构完整的预测信号的方法，该方法在训练和预测时会增加计算量，降低检测器效率，新算法在重构信号后预测，降低运算量、缩短时间、提高检测性能。整体算法步骤如下：

1）对信号进行去噪，利用 Cao 法和改进自相关函数确定嵌入维数、时延，重构信号相空间；

2）初始化 BA，KELM 参数，输入训练信号；

3）用改进 BA 算法优化 KELM 模型参数；

4）训练优化后的 KELM 预测模型；

5）输入待检测信号，进行单步预测，并计算预测均方误差 RMSE，即 $E_{\text{RMSE}} = \frac{1}{N'}\sum_{i=1}^{N'} |\hat{x}(t) - x(t)|^2$，其中，$x(t)$，$\hat{x}(t)$，$N'$ 分别为输入、输出信号与采样点数；

6）设定 RMSE 门限 η，如果 RMSE 大于门限，则表示检测信号中含目标信息。

2.4　仿真实验

为验证新算法性能，对比实测数据去噪前后波形，验证新算法对海杂波的抑制效果。同时对 IPIX 雷达实测数据做混沌预测，对其中漂浮小目标进行检测。同等情况下对比新算法与传统混沌预测算法，结果证明，新算法预测效果和稳定性更好。

实验使用 1993 年 IPIX 雷达的实测数据，取#310 数据第 4 单元（HH 极化）的 1024 个采样点，将信号预处理后，EEMDCAN 分解得 9 个 *imf* 与剩余项，分解结果如图 1，其中，$r(t)$ 为剩余分量信号。低阶 *imf* 分量含更多高频分量，噪声与杂波占主导，高阶分量中目标信息占主导。

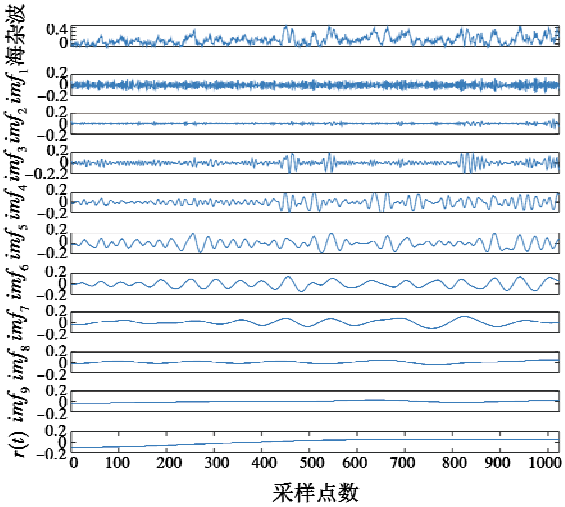

图 1　EEMDCAN 分解结果

Fig. 1　EEMDCAN decomposition results

计算 9 个 *imf* 分量排列组合熵 H_{PE}，见表 2，将熵差 ΔH_{PE} 小于 0.1 的相邻 *imf* 分量做模态合并。$imf_1 \sim imf_3$ 合并为重组分量 IMF_1，$imf_4 \sim imf_6$ 分别为重组分量 $IMF_2 \sim IMF_4$，$imf_7 \sim imf_9$ 合并为重组分量 IMF_5，具体如图 2 所示。

表 2 各 *imf* 分量排列组合熵值表

Table 2 Entropy of *imf* components

分量	$H_{PE}(m)$	$\Delta H_{PE}(m)$	分量	$H_{PE}(m)$	$\Delta H_{PE}(m)$
imf_1	0.9956	0.0153	imf_6	0.4851	0.1231
imf_2	0.9803	0.0091	imf_7	0.3620	0.0363
imf_3	0.9712	0.1386	imf_8	0.3257	0.0561
imf_4	0.8326	0.1748	imf_9	0.2696	–
imf_5	0.6578	0.1727			

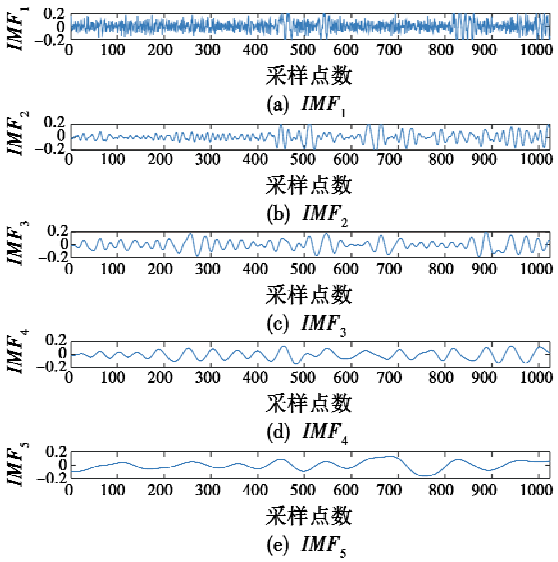

图 2 模态合并结果

Fig. 2 Modal merging results

计算重组 *IMF* 分量与原信号互相关系数曲线得到图 3。

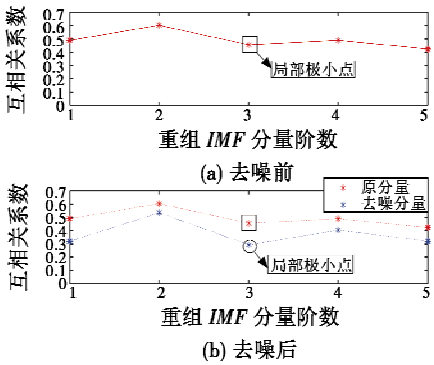

图 3 互相关系数曲线

Fig. 3 Curves of cross-correlation coefficients

除一阶 *IMF* 之外，首个极小值点所对应的分量是 IMF_3，将 $IMF_1 \sim IMF_3$ 作为 Robust ICA 的输入信号，完成分离后滤除噪声；IMF_4，IMF_5 做 SG 滤波；滤波完成后进行条件判决，判断是否满足输出条件。重组 *IMF* 分量处理后，各 *IMF* 分量的相关系数曲线的原曲线与处理后的曲线形状和走势一致，且极小点对应的重组 *IMF* 分量阶数一致，因此在抑制海杂波时，仍保留了信号特性，不破坏信号的混沌特性。将重组 *IMF* 分量重构，输出结果如图 4 所示，极大程度地滤除了海杂波且保留了信号波形特点，证明本文算法在抑制海杂波方面具有很好的效果。

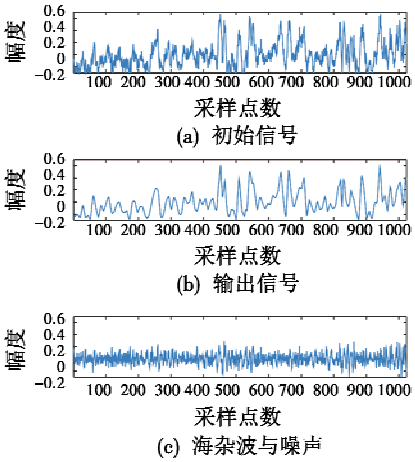

图 4 海杂波去噪处理效果

Fig. 4 Denoising effect of sea clutter

KELM 常用 RBF 核、小波核（近似）正交，而非小波核相关甚至冗余，因此选取多维张量积小波核

$$K(x_i,x_j)=\prod_{q=1}^{n}\left(\cos\frac{1.75(x_i^q-x_j^q)}{a}\right)\exp\left(-\frac{(x_i^q-x_j^q)^2}{2\sigma^2}\right) \tag{11}$$

式中，a 为核计算中的内参数。

利用改进 BA 算法优化模型。改进 BA 算法的最大迭代次数为 200，种群数量是 25，最大与最小频率分别为 2 和 0，初始响度 1，初始脉冲速率 0.5。

用#310 数据第 5 距离单元数据训练模型，从第 8 单元中取 1024 点数据，进行混沌预测。预测结果与预测误差如图 5 所示。

由图 5 可知，对纯海杂波预测效果很好，预测绝对误差不超过 10^{-16}，预测结果 RMSE 为 $2.85\,991\times10^{-30}$，无限接近 0，可见预测极精确。对第 7 单元的数据预测，误差就远大于纯海杂波的预测误差，因此可以此作为小目标特征，预测结果的 RMSE 可作为目标检测的量化指标。

为验证新算法的可行性与优越性，利用 BP，SVM，ELM，KELM 分别对#310（HH 极化）数据的去噪数据进行训练和预测。根据预测结果 RMSE、训练时长、预测时长等指标验证算法性能得到表 3。

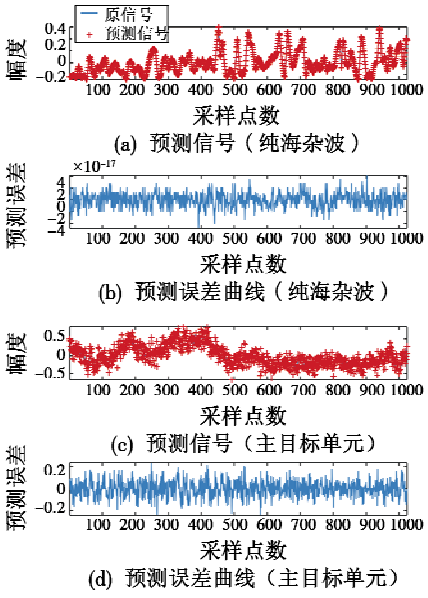

图 5　海杂波预测结果分析

Fig. 5　Analysis of sea clutter prediction results

表 3　不同模型检测结果对比分析

Table 3　Comparison and analysis of test results of different models

数据	算法	RMSE	训练时长/s	预测时长/s
#310（HH 极化）纯海杂波	BP	5.24435×10^{-4}	180.25343	0.7143
	SVM	3.83341×10^{-11}	3.327	0.7223
	ELM	1.88521×10^{-13}	0.416	0.1143
	KELM	8.78513×10^{-23}	0.761	0.2001
	本文算法	2.85991×10^{-33}	0.945	0.1002
#310（HH 极化）主目标单元	BP	0.0035	176.37642	0.6853
	SVM	0.0031	3.657	0.6932
	ELM	0.0045	0.396	0.1203
	KELM	0.0034	0.631	0.1821
	本文算法	0.0026	0.901	0.1104

由表 3 可得，同等条件下，BP 神经网络训练时间最长，ELM 训练时间最短，KELM 略大于 ELM，本文算法优化 KELM 模型参数，因此训练时长比单一 KELM 更长，但总体而言，本文算法在训练速度上仍具有很大优势。纯海杂波预测过程中，本文算法 RMSE 最小（无限接近 0），远小于其他预测模型，说明本文算法模型对纯海杂波预测最精确、效果最佳；而反观主目标单元预测结果，本文算法的 RMSE 仍然最小，但与其他算法相比却没有数个数量级的差距，因此根据此变化可以更好地设置门限，若大于门限，则判定有目标，否则无目标。由此可知：本文算法可快速、高效地检测海面小目标。

为研究信号信杂比对检测性能的影响，仿真 1024 个点微弱目标信号，即

$$s(n)=b\exp\left(-\pi\left(\frac{n-200}{400}\right)^2\right)\exp(\mathrm{j}2\pi(0.00005n^2)) \quad (12)$$

式中：b 为幅度；n 为计数序号，$0\leqslant n\leqslant 1023$。将第 8 单元的 1024 点纯海杂波数据（杂噪比约 19 dB）作为杂波信号，根据信杂比构造出回波信号。检测前，对信号联合去噪，输入已训练完成的模型中进行混沌预测，计算 RMSE 进行目标检测。强杂波环境下，微弱目标检测性能会严重下降。通过蒙特卡罗实验，计算不同信杂比下算法的检测概率，结果如图 6 所示。

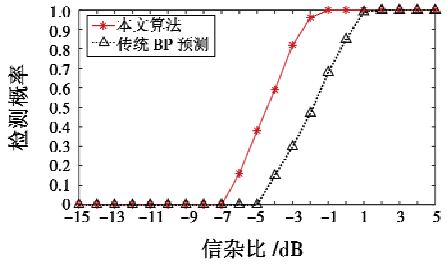

图 6　检测概率对比曲线

Fig. 6　Detection probability comparison

由图 6 可知，本文算法不仅在检测时效性方面明显优于传统 BP 算法，不同信杂比下的检测性能也显著优于传统 BP 算法。

3　结束语

本文算法以海杂波混沌特性为基础，利用 EEMD-CAN-Robust ICA & SG 滤波算法抑制海杂波，并利用改进的混沌预测模型精确预测纯海杂波信号，结果证明预测效果极好。对信号做小目标检测时，检测器性能稳定，能够有效检测漂浮小目标信息。本文算法改善了海杂波混沌预测受噪声影响严重的问题，提升了混沌预测的准确性，且大幅缩短了训练时间，提高了检测效率及算法在工程中的可行性。低信杂比下，本文算法检测性能显著优于传统算法。

参 考 文 献

[1] 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.

[2] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.

[3] YEH J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method [J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.

（下转第 84 页）

随机误差实时滤波研究[J]. 电光与控制,2019,26(5):68-72.

[10] CHEN M M, GAO G W. Research on MEMS gyroscope random error compensation algorithm based on ARMA model[J]. Applied Mechanics & Materials, 2014, 602-605:891-894.

[11] 曾庆化,黄磊,刘建业,等. 基于ARMA模型的光纤陀螺随机噪声滤波方法[J]. 中国惯性技术学报,2015,23(1):120-124.

[12] 代金华,张丽杰. 多准则MEMS陀螺随机误差在线建模与实时滤波[J]. 传感技术学报,2016,29(1):75-79.

[13] LI L. Random error recognition and noise reduction technology of MEMS gyro[C]//The International Conference on Artificial Intelligence and Computer Science, 2019:713-716.

[14] 孙伟,吴增林,耿诗涵,等. ARMA模型的MEMS陀螺随机误差卡尔曼补偿方法[J]. 测绘科学,2017,42(12):52-56,82.

[15] 吕铁军,蒋宏,丁全心,等. 基于角速度估计自适应的IMM目标跟踪算法[J]. 航空科学技术,2012(1):74-77.

[16] 吴苗,郭士荦,许江宁. 强跟踪扩展卡尔曼滤波及其在捷联惯导初始对准中的应用[J]. 海军工程大学学报,2019,31(3):12-16.

(上接第55页)

[4] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. Complete ensemble empirical mode decomposition with adaptive noise[C]//IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2011:4144-4147.

[5] 蔡念,黄威威,谢伟,等. 基于互补自适应噪声的集合经验模式分解算法[J]. 电子与信息学报,2015,37(10):2383-2389.

[6] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine:theory and applications[J]. Neurocomputing, 2006, 70(1-3):489-501.

[7] HUANG G B, ZHOU H M, DING X J, et al. Extreme learning machine for regression and multiclass classification [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2012, 42(2):513-529.

[8] BANDT C, POMPE B. Permutation entropy:a natural complexity measure for time series[J]. Physical Review Lettes, 2002, 88(17):174102.

[9] HYVARINEN A, OJA E. A fast fixed-point algorithm for independent component analysis[J]. Neural Computation, 1997, 9(7):1483-1492.

[10] ZARZOSO V, COMON P. Robust independent component analysis by iterative maximization of the Kurtosis contrast with algebraic optimal step size[J]. IEEE Transactions on Neural Networks, 2010, 21(2):248-261.

[11] YANG X S. A new metaheuristic bat-inspired algorithm [M]//GONZÁLEZ J R, PELTA D A, CRUZ C, et al. Nature inspired cooperative strategies for optimization. Berlin:Springer, 2010.

请扫描二维码关注我刊