

基于三特征预测的海杂波中小目标检测方法

董云龙 张兆祥 丁昊* 黄勇* 刘宁波
(海军航空大学 烟台 264001)

摘要: 特征检测方法是解决海杂波中小目标检测问题的重要途径,其根据特征值是否在判决区域内判断目标有无,几乎不考虑特征间的时序信息。事实上,历史帧数据与当前帧数据的时序关联性,可以为当前帧特征值的计算提供丰富的先验信息。为此,该文提出了一种使用自回归(AR)模型在特征域对雷达回波进行时序建模和预测的方法,以利用历史帧特征的先验信息。首先,使用AR模型对平均幅度(AA)、相对多普勒峰高(RDPH)、频谱峰均比(FPAR)特征序列进行建模和1步预测分析,验证了对特征序列进行AR建模和预测的可行性。其次,提出利用历史帧特征时序信息作为先验信息的特征值提取方法,在此基础上,提出一种基于三特征预测的小目标检测方法,该方法可有效利用AA, RDPH和FPAR的历史帧特征时序信息。最后,使用实测数据验证了所提方法的有效性。

关键词: 目标检测; 海杂波; 历史帧特征; 先验信息; 特征预测

中图分类号: TN957.51

文献标识码: A

文章编号: 2095-283X(2023)04-0762-14

DOI: 10.12000/JR23037

引用格式: 董云龙, 张兆祥, 丁昊, 等. 基于三特征预测的海杂波中小目标检测方法[J]. 雷达学报, 2023, 12(4): 762–775. doi: 10.12000/JR23037.

Reference format: DONG Yunlong, ZHANG Zhaoxiang, DING Hao, *et al.* Target detection in sea clutter using a three-feature prediction-based method[J]. *Journal of Radars*, 2023, 12(4): 762–775. doi: 10.12000/JR23037.

Target Detection in Sea Clutter Using a Three-feature Prediction-based Method

DONG Yunlong ZHANG Zhaoxiang DING Hao* HUANG Yong* LIU Ningbo
(Naval Aviation University, Yantai 264001, China)

Abstract: Feature-based detection methods are often employed to address the challenges related to small-target detection in sea clutter. These methods determine the presence or absence of a target based on whether the feature value falls within a certain judgment region. However, such methods often overlook the temporal information between features. In fact, the temporal correlation between historical and current frame data can provide valuable a priori information, thereby enabling the calculation of the feature value of the current frame. To this end, this paper proposes a novel method for time-series modeling and prediction of radar echoes using an Auto-Regressive (AR) model in the feature domain, leveraging a priori information from historical frame features. To verify the feasibility of AR modeling and prediction of feature sequences, the AR model was first employed in the modeling and 1-step prediction analysis of Average Amplitude (AA), Relative Doppler Peak Height (RDPH), and Frequency Peak-to-Average Ratio (FPAR) feature sequences. Next, a technique for extracting feature values by utilizing the temporal information of historical frame features as a priori information was proposed. Based on this approach, a small-target detection method predicated on three-feature prediction, which can effectively utilize the temporal information of historical frame features for AA, RDPH, and FPAR, was proposed. Finally, the validity of the proposed method was verified using a measured data set.

Key words: Target detection; Sea clutter; Historical frame features; Prior information; Feature prediction

收稿日期: 2023-03-23; 改回日期: 2023-05-11; 网络出版: 2023-05-31

*通信作者: 丁昊 hao3431@tom.com; 黄勇 huangyong2003@163.com

*Corresponding Authors: DING Hao, hao3431@tom.com; HUANG Yong, huangyong2003@163.com

基金项目: 国家自然科学基金(62101583, 61871392), 泰山学者工程(tsqn202211246)

Foundation Items: The National Natural Science Foundation of China (62101583, 61871392), The Taishan Scholars Program (tsqn202211246)

责任主编: 许述文 Corresponding Editor: XU Shuwen

1 引言

对海面漂浮小目标进行检测是对海探测雷达的主要任务之一，此类目标主要包括航道浮标、小船等，具有雷达回波微弱的特点^[1,2]。在高分辨率体制雷达中，海杂波具有明显的非平稳、非均匀和非高斯性，海杂波特性复杂，且在高分辨率、低擦地角和高海况条件下，易出现海尖峰，因此传统的非相干检测和自适应类相干检测方法很难实现漂浮小目标的有效检测^[3]。

作为一类新兴的雷达目标检测方法，特征检测方法是提升海杂波中小目标检测性能的重要途径。特征检测方法一方面可以有效利用高分辨率雷达提供的丰富回波信息，另一方面可以将雷达目标检测问题转化为分类问题解决，简化目标检测问题的复杂度。目前已提出了大量具有较好可分性的特征，如分形类特征^[4-6]、时频类特征^[7,8]、极化域特征^[9,10]、图特征^[11,12]、相位域^[13]和奇异谱域特征^[14]等。特征检测方法一般只利用当前帧数据提取特征，而当前帧数据所含信息量有限，虽然可通过增加脉冲数方法提升特征区分度，但会影响雷达的探测效率。事实上，秒级观测时间尺度及其对应的探测空间尺度，相较于长时间观测及广域海面所带来的变化可忽略不计。可预测的是，数秒时间内的历史帧数据与当前帧必然存在某种关联，这种关联即为历史帧数据对当前帧提供的先验信息，可以帮助我们更加准确地计算当前帧特征值，而经典特征检测方法常忽略历史帧特征先验信息对当前帧特征的影响，造成了较大的信息浪费。目前，虽然有少量文献利用了历史帧特征信息，但其仅进行了帧间特征累积或只利用了历史帧特征的分布信息^[15,16]，显然没有涉及历史帧特征数据的时序属性，而时序属性是雷达回波数据的本质属性。经典特征检测方法一般只关注特征在特征空间的分布情况，事实上，帧间特征

蕴含丰富的时序信息，图1可以帮助我们更好地理解帧间特征的时序关系。图1中“当前帧特征观测值”是由当前帧数据直接计算的特征值，“当前帧特征预测值”是根据历史帧特征变化规律预测的特征值，“当前帧特征融合值”是融合了当前帧特征观测值和预测值信息之后的特征值。帧间特征的时序信息主要有两种用途，一是作为历史帧特征的先验信息，用于融合产生当前帧特征融合值，修正当前帧特征值，如图1右侧部分所示；二是将时序信息直接用于目标检测或识别，实现特征空间中无法直接区分目标的检测或识别。鉴于此，本文提出使用自回归(Auto-Regressive, AR)模型在特征域对雷达回波进行时序建模和预测，以利用历史帧特征先验信息，并在此基础上形成新的特征用于检测。该方法主要有两个优势，一是数秒内，在特征域，雷达回波可看作近似平稳时间序列，故可使用平稳时序模型建模，简化了雷达回波时序模型复杂度；二是由于融合利用了历史帧特征先验信息，新生成的特征具有更好的可分性。

本文首先介绍特征序列的时序建模和预测方法，并基于实测数据，分析了3种特征序列的AR建模和1步预测结果，验证了对特征序列进行AR建模和预测的可行性。其次，介绍了利用先验信息的特征值提取方法，提出了一种基于三特征预测的海面小目标检测方法。最后，使用实测数据验证了所提方法的有效性。

2 特征提取与特征序列的时序建模

本节首先介绍特征序列的AR建模和预测方法，其次回顾3种区分性较好的已知特征，最后基于IPIX (Intelligent PIXel processing X-band)雷达数据，分析3种特征序列的AR建模和1步预测结果，验证对特征序列进行AR建模和预测的可行性。

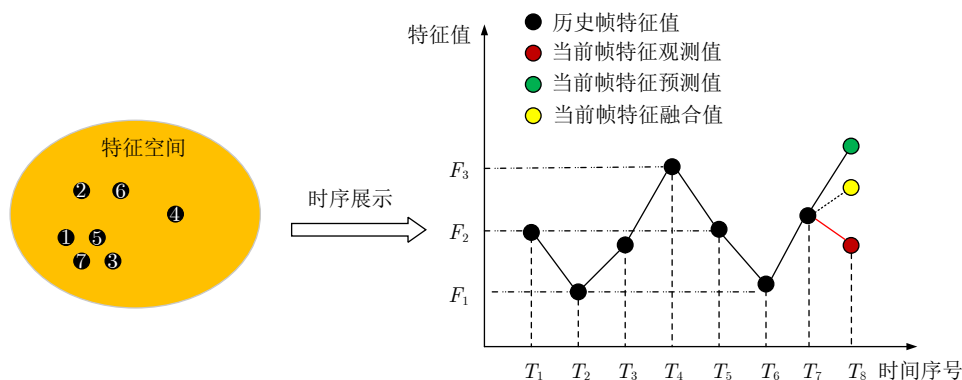


图1 帧间特征值的时序关系示意图

Fig. 1 Schematic diagram of the temporal relationship of the features between frames

2.1 特征序列的AR建模和预测方法

以往文献已经证明, 在小于几秒的时间尺度上, 海杂波可建模为4阶或5阶的AR模型^[17,18], 鉴于此, 本文对海杂波时序建模方法进行推广, 提出了特征序列的AR建模方法。

假设某距离单元上接收到一串脉冲, 提取特征之后得到连续 T 个特征观测值 $\{X_1, X_2, \dots, X_T\}$, 对该特征序列进行AR模型拟合之前, 需要先判断特征序列的平稳性、确定拟合模型阶数。可通过特征序列的自相关函数、偏自相关函数和时序图大致判断序列的平稳性及适用的AR模型阶数, 通常使用自相关系数(Autocorrelation Coefficient, AC)代替自相关函数、偏自相关系数(Partial Autocorrelation Coefficient, PAC)代替偏自相关函数表征样本的相关性, 任意时间序列 $\{x_1, x_2, \dots, x_t, \dots, x_T\}$ 的AC定义如下^[19]:

$$\rho_k = \frac{\gamma_k}{\gamma_0} \quad (1)$$

其中, γ_0 为时间序列 $\{x_1, x_2, \dots, x_t, \dots, x_T\}$ 的方差, γ_k 为间隔 k 的自协方差。PAC定义如下:

$$\rho_{x_t, x_{t-k} | x_{t-1}, x_{t-2}, \dots, x_{t-k+1}} = \frac{E \left[\left(x_t - \hat{E}x_t \right) \left(x_{t-k} - \hat{E}x_{t-k} \right) \right]}{E \left[\left(x_{t-k} - \hat{E}x_{t-k} \right)^2 \right]} \quad (2)$$

其中, $E(\cdot)$ 表示期望, $\hat{E}x_t = E[x_t | x_{t-1}, x_{t-2}, \dots, x_{t-k+1}]$, $\hat{E}x_{t-k} = E[x_{t-k} | x_{t-1}, x_{t-2}, \dots, x_{t-k+1}]$, PAC是条件自协方差函数与条件方差的比值, 实质是条件自相关系数。

序列平稳性的一种判定依据是平稳序列通常具有短期相关性, 对于平稳的时间序列, AC往往会迅速退化到0(滞后期越短相关性越高, 滞后期为0时, 相关性为1)^[20]。当特征序列为平稳序列时, 如果其AC为拖尾, PAC为 p 步截尾, 表明特征序列可以使用AR模型建模, 且AR模型阶数为 p 。

具有式(3)结构的模型称为 p 阶AR模型, 记为AR(p)。

$$\begin{cases} x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + \varepsilon_t \\ \phi_p \neq 0 \\ E(\varepsilon_t) = 0, \text{Var}(\varepsilon_t) = \sigma_\varepsilon^2, E(\varepsilon_t \varepsilon_s) = 0, s \neq t \\ E(x_s \varepsilon_t) = 0, \forall s < t \end{cases} \quad (3)$$

其中, 扰动项 ε_t 是零均值、方差为 σ_ε^2 的平稳白噪声。特别的, 当 $\phi_0=0$ 时, 称为中心化AR(p)模型, 一般使用中心化AR(p)模型对时间序列进行拟合。

时间序列的AR模型拟合最佳阶数 p 可通过贝叶斯信息准则(Bayesian Information Criterion, BIC)估计, 定义如下:

$$\text{BIC}(p) = \ln \hat{\sigma}^2 + \frac{(p+1) \ln M}{M} \quad (4)$$

使得BIC达到最小值的 p , 即为通过贝叶斯信息准则确定的AR模型最佳阶数。式(4)中, M 为时间序列长度, $\hat{\sigma}^2$ 为与阶数相对应的AR模型白噪声方差的最大似然估计值。

使用中心化AR(p)模型对特征序列 $\{X_1, X_2, \dots, X_T\}$ 进行拟合的结果如下:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t \quad (5)$$

其中, 模型阶数 p 为已知量, 模型参数 $\phi = (\phi_1, \phi_2, \dots, \phi_p)^T$ 为待估计参数, 其矩估计值 $\hat{\phi} = (\hat{\phi}_1, \hat{\phi}_2, \dots, \hat{\phi}_p)^T$ 可通过式(6)计算。

$$\begin{bmatrix} \hat{\rho}_1 \\ \hat{\rho}_2 \\ \vdots \\ \hat{\rho}_p \end{bmatrix} = \begin{bmatrix} 1 & \hat{\rho}_1 & \dots & \hat{\rho}_{p-1} \\ \hat{\rho}_1 & 1 & \dots & \hat{\rho}_{p-2} \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\rho}_{p-1} & \hat{\rho}_{p-2} & \dots & 1 \end{bmatrix} \begin{bmatrix} \hat{\phi}_1 \\ \hat{\phi}_2 \\ \vdots \\ \hat{\phi}_p \end{bmatrix} \quad (6)$$

其中, $\hat{\rho}$ 为特征序列 $\{X_1, X_2, \dots, X_T\}$ 的AC, 式(6)称为参数的尤尔-沃克方程估计法。白噪声方差 σ_ε^2 的矩估计值 $\hat{\sigma}_\varepsilon^2$ 如下^[21]:

$$\hat{\sigma}_\varepsilon^2 = \hat{\gamma}_0 - \sum_{j=1}^p \hat{\phi}_j \hat{\gamma}_j \quad (7)$$

其中, $\hat{\gamma}_0$ 为特征序列的方差, $\hat{\gamma}_j$ 为间隔 j 的自协方差。事实上, AR模型非常适合进行短期预测, 特别是1步预测^[21], 故特征序列 $\{X_1, X_2, \dots, X_T\}$ 建模为式(5)所示的AR(p)序列之后, 特征在下一时刻的预测值可使用式(8)计算。

$$\hat{X}_T(1) = \phi_1 X_T + \phi_2 X_{T-1} + \dots + \phi_p X_{T+1-p} \quad (8)$$

其中, $\hat{X}_T(1)$ 为 $T+1$ 时刻的特征预测值, 即特征在下一时刻的预测值, 1步预测误差如下:

$$e_h(1) = X_{T+1} - \hat{X}_T(1) = \varepsilon_{T+1} \quad (9)$$

其中, $e_h(1)$ 为1步预测误差, X_{T+1} 为特征在 $T+1$ 时刻的观测值。

2.2 已知三特征介绍

本节简要介绍3种已知特征的提取方法, 3种特征均具有可分性好、计算简单和物理含义明确的特点。作为一种最基础的时域能量特征, 平均幅度(Average Amplitude, AA)特征具有明确的物理含义, 雷达回波 $\{z(n), n=1, 2, \dots, N\}$ 的AA定义如下^[22]:

$$\text{AA}(z) = \frac{1}{N} \sum_{n=1}^N |z(n)| \quad (10)$$

其中, z 为雷达回波时间序列排列的向量。平均幅

度是传统雷达目标检测的主要特征, 信杂比(Signal-Clutter Ratio, SCR)较高时, 该特征区分性较好。

文献[22]提出了相对多普勒峰高(Relative Doppler Peak Height, RDPH)特征, 同时证明了特征的有效性。雷达回波 $\{z(n), n = 1, 2, \dots, N\}$ 的多普勒幅度谱计算如下:

$$Z(f_d) = \frac{1}{\sqrt{N}} \left| \sum_{n=1}^N z(n) \exp(-2\pi f_d n \text{PRP}) \right|, \quad -\frac{1}{2\text{PRP}} \leq f_d \leq \frac{1}{2\text{PRP}} \quad (11)$$

其中, f_d 为多普勒频率, PRP为脉冲重复周期。多普勒峰高和多普勒偏移量的计算公式如下:

$$\begin{cases} \text{Peak}(z) = \max_{f_d} \left\{ Z(f_d), -\frac{1}{2\text{PRP}} \leq f_d \leq \frac{1}{2\text{PRP}} \right\} \\ f_d^{\max}(z) = \arg \max_{f_d} \left\{ Z(f_d), -\frac{1}{2\text{PRP}} \leq f_d \leq \frac{1}{2\text{PRP}} \right\} \end{cases} \quad (12)$$

设 δ_1 为供参考的多普勒单元范围, δ_2 为目标的最大多普勒带宽, 例如, 可选择 $\delta_1 = 50$ Hz, $\delta_2 = 5$ Hz。RDPH定义如下:

$$D = [-\delta_1, -\delta_2] \cup [\delta_2, \delta_1] \\ \text{RDPH}(z) = \frac{\text{Peak}(z)}{\frac{1}{\#D} \sum_{f_d \in f_d^{\max}(z)+D} Z(f_d)} \quad (13)$$

其中, D 表示多普勒参考单元组成的集合, \cup 表示并集, $\#D$ 表示集合 D 内元素个数。

文献[23]提出了频谱峰值均值比(Frequency Peak to Average Ratio, FPAR)特征, 同时证明了该特征的有效性。雷达回波 $\{z(n), n = 1, 2, \dots, N\}$ 的FPAR定义如下:

$$\text{FPAR}(z) = \frac{\max\{F(k), k = 1, 2, \dots, N\}}{\frac{1}{N} \sum_{k=1}^N F(k)} \quad (14)$$

$F(k)$ 表示 $z(n)$ 经 N 点离散傅里叶变换得到的幅度谱。含目标回波单元的FPAR一般大于纯海杂波单元。

2.3 特征序列的AR建模及1步预测分析

本节基于IPIX雷达数据, 分析AA, RDPH和FPAR特征序列的AR建模和1步预测结果, 验证对特征序列进行AR建模和预测的可行性, 所使用IPIX雷达数据的详细介绍见4.1节。

(1) 海杂波特征序列的平稳性判断及AR模型阶数确定

本文通过计算整个数据集海杂波AA, RDPH和FPAR特征序列的平均自相关系数和平均偏自相关系数, 判断整个数据集海杂波特征序列的大致平稳性。使用HH_#320数据, 每256个脉冲提取一次AA, RDPH和FPAR特征, 纯海杂波距离单元上连续100个特征计算一次AC和PAC, 最终得到的3种特征的平均自相关系数和平均偏自相关系数如图2所示, BIC估计的3种特征序列的AR模型最佳系数如图3所示。显然, 3种特征的平均自相关系数均为指数型衰减, 具有明显拖尾特性, 平均偏自相关系数均有明显截尾特性。事实上, 10组IPIX雷达数据上均有类似现象, 且不受极化方式影响。这表明整体而言, 海杂波中提取的AA, RDPH和FPAR特征序列是近似平稳的, 且3种特征序列均可使用AR模型拟合。图3表明BIC确定的AA特征序列的AR模型最佳阶数主要在6阶附近, RDPH和FPAR特征序列的AR模型最佳阶数主要在1阶、2阶附近, 且3种特征序列的最佳阶数分布在1~7阶之间。事实上, 当阶数为1~7阶时, 估计的AR模型对

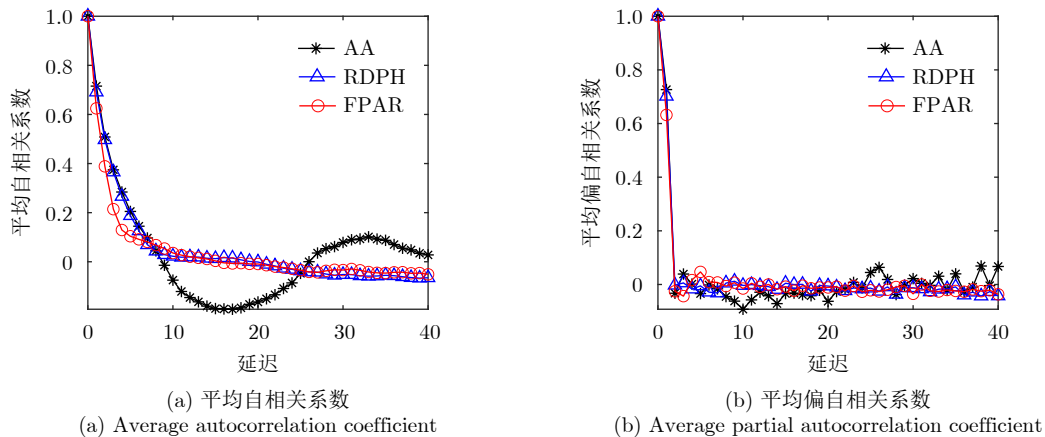


图2 3种特征的平均自相关系数与平均偏自相关系数

Fig. 2 Average autocorrelation coefficient and average partial autocorrelation coefficient for the three features

RDPH, FPAR特征序列的拟合和1步预测效果相差不大,阶数为3~7阶时,估计的AR模型对AA特征序列的拟合和1步预测效果相差不大,因此,为使固定阶数的AR模型适用于整个数据集,模型最佳阶数经验值可设为3~7阶。

(2) 海杂波特征序列的AR模型拟合结果分析

使用HH_#320数据,分析海杂波AA, RDPH和FPAR特征序列的AR模型拟合结果。每256个脉冲提取一次AA, RDPH和FPAR特征,连续100个特征观测值使用AR模型拟合一次,AR模型经验阶数设为5,典型特征观测值的AR模型拟合结果如图4。显然,AR模型能够较好地拟合海杂波AA, RDPH和FPAR特征序列。其中,AA特征的AR模型拟合效果最佳,其次是RDPH,最后是FPAR,可通过图2进行解释。AA特征序列的平均自相关系数衰减最平缓,且延迟1阶的平均偏自相关系数最

大,这表明AA特征序列的自相关性最佳,最符合AR序列的特点,RDPH次之,最后是FPAR。事实上,为提升3种特征序列的AR模型拟合效果,特征提取时,相邻特征使用的脉冲数据向量可部分重叠。

(3) 海杂波特征序列的AR模型1步预测结果分析

使用10组HH极化的IPIX雷达数据,分析海杂波AA, RDPH和FPAR特征序列的AR模型1步预测结果,以判断海杂波AA, RDPH和FPAR特征序列的可预测性。每256个脉冲提取一次AA, RDPH和FPAR特征,为提升特征序列的平稳性、相关性和AR模型拟合效果,特征提取时,时间相邻特征使用的脉冲数据存在128个脉冲重叠。连续100个特征使用AR(5)模型拟合一次,并计算1步预测误差,实验结果如表1和图5所示。可知,使用AR模型能




图 3 BIC估计的3种特征序列的AR模型最佳阶数

Fig. 3 Optimal order of AR models for the three feature sequences estimated by the BIC




图 4 3种特征的AR模型拟合结果(海杂波)

Fig. 4 AR model fitting results for three features (sea clutter)

表 1 3种特征的预测结果
Tab. 1 Predicted results of the three features

数据	平均幅度			相对多普勒峰高			频谱峰均比		
	误差均值	误差标准差	误差(%)	误差均值	误差标准差	误差(%)	误差均值	误差标准差	误差(%)
#17	0.0002	0.2167	7.58	-0.0049	0.1716	11.46	-0.0746	2.6394	15.51
#26	-0.0074	0.1790	10.90	-0.0067	0.1989	13.11	-0.2254	4.2131	16.72
#30	-0.0087	0.1576	10.05	-0.0069	0.2029	13.45	-0.2353	4.0889	17.54
#31	-0.0114	0.1769	11.42	-0.0069	0.2002	13.21	-0.2462	4.1325	17.43
#40	-0.0135	0.2101	12.10	-0.0072	0.2036	13.36	-0.2831	4.4131	18.25
#54	-0.0048	0.1991	11.53	-0.0055	0.1821	12.59	-0.1536	3.1127	15.31
#280	-0.0114	0.1751	10.87	-0.0059	0.1864	12.21	-0.2316	4.2699	17.04
#310	-0.0064	0.1280	7.71	-0.0046	0.1722	11.26	-0.1023	2.3707	13.11
#311	-0.0067	0.1330	8.57	-0.0051	0.1850	12.09	-0.1216	2.7095	14.12
#320	-0.0055	0.1281	8.04	-0.0065	0.2035	13.75	-0.1229	2.6733	14.34




图 5 3种特征的AR模型1步预测结果

Fig. 5 1-step prediction results of AR models with three features

够较好地对海杂波AA, RDPH和FPAR特征序列进行拟合和1步预测。其中, AR(5)模型对AA特征序列的1步预测平均误差在10%左右, 对RDPH特征序列的1步预测平均误差在12%左右, 对FPAR特征序列的1步预测平均误差在15%左右。显然, AA特征序列的平均预测误差最小, 其次是RDPH特征, 最后是FPAR特征, 主要原因是AA特征序列的AR模型拟合效果最好。

HH_#320数据得到的含目标回波单元的AA, RDPH和FPAR特征序列的AR(5)模型拟合结果如图6, 显然可以使用AR模型较好地拟合含目标回波单元的AA, RDPH和FPAR特征序列。事实上, 实测数据分析表明, 含目标回波单元的AA, RDPH和FPAR特征序列也可使用AR模型进行1步预测, 且AR模型的经验阶数也可设为3~7阶。

综上所述, 可以使用AR模型对AA, RDPH和FPAR特征序列进行建模和1步预测, 且能达到较好的拟合和预测效果, 其中AR模型的经验阶数可设为3~7阶, 为增大特征序列的平稳性和相关性, 提升特征序列的AR模型拟合和预测效果, 特征提取时, 时间相邻特征使用的脉冲数据向量可部分重叠。

3 基于三特征预测的目标检测方法

3.1 利用先验信息的特征值提取方法

传统特征值提取方法一般不考虑任何先验信息, 只使用当前帧数据, 而当前帧数据量有限, 可能受到同频干扰、噪声等影响, 导致提取的特征值误差较大, 不能表征当前帧的真实特征值水平, 鉴于此, 本节提出一种利用先验信息的特征值提取方

法。上文已经验证了对特征序列进行AR建模和预测的可行性，故本节将历史帧特征数据的时序规律作为先验信息，融合当前帧特征预测值与当前帧特征观测值，得到当前帧特征融合值，具体流程如图7所示，图中序号表示执行步骤顺序。鉴于海洋环境的短期平稳、长期非平稳特性，那么短期内历史帧数据与当前帧具有关联性。因此，首先将固定帧数历史帧窗口内的特征观测值作为可利用的历史帧数据，对其AR模型拟合，提取时序信息作为先验信息；其次融合当前帧特征观测值与先验信息，得到当前帧特征融合值；接着使用当前帧特征观测值更新历史帧特征数据，删除原历史帧特征数据中最早的特征值，只保留新历史帧窗口内特征值；最后，使用AR模型拟合新历史帧特征数据，重新提

取特征时序信息作为先验信息，用于下一帧特征提取。上述操作流程一直循环重复直至雷达停止工作。

利用先验信息的当前帧特征融合值具体计算方法如下：

$$\begin{cases} X_{\text{true}} = \alpha_1 X_{\text{obse}} + \alpha_2 X_{\text{fore}} \\ \alpha_1 + \alpha_2 = 1, \alpha_1 \geq 0, \alpha_2 \geq 0 \end{cases} \quad (15)$$

其中， X_{true} 为当前帧特征融合值； X_{obse} 为当前帧特征观测值； X_{fore} 为当前帧特征预测值，通过对历史帧特征序列进行AR拟合与1步预测得到； α_1, α_2 为加权系数，分别表征当前帧数据、历史帧数据对当前帧特征融合值的影响程度，可预见的是，二者应当与当前海洋环境状况相关，一般海况条件下， X_{obse} 和 X_{fore} 对 X_{true} 的贡献基本相同，当海况等级较




图 6 3种特征的AR模型拟合结果(含目标回波)

Fig. 6 AR model fitting results for three features (target echo)

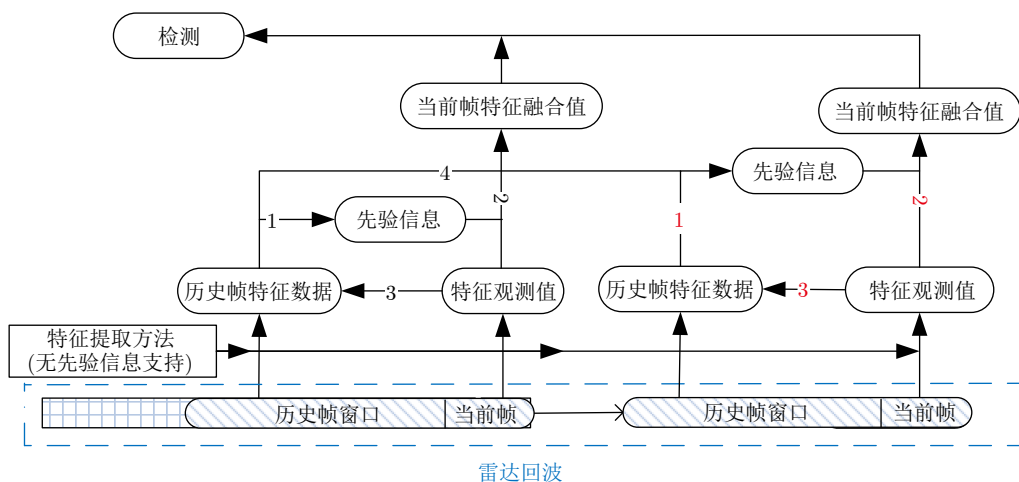


图 7 利用先验信息的特征提取方法示意图

Fig. 7 The schematic diagram of the feature extraction method using prior information

高时, X_{obse} 对 X_{true} 的影响大于 X_{fore} , 可根据具体探测场景确定二者取值。

3.2 海杂波中漂浮小目标检测问题

假设高分辨率对海探测雷达, 在某波束方位上发射长度为 L 的相干脉冲串, 并在每个距离单元上接收长度为 L 的复向量 $\mathbf{y}(l)$ 。当该距离单元存在目标时, 回波由目标回波、海杂波和噪声组成, 否则只包含海杂波和噪声。并假设待检测单元(Cell Under Test, CUT)周围距离单元接收到的回波只包含海杂波和噪声, 当杂噪比较高时, 噪声忽略不计, 海面漂浮小目标检测问题转化为以下二元假设检验问题^[22]:

$$\begin{cases} H_0: \begin{cases} \mathbf{y}(l) = c(l) \\ \mathbf{y}_v(l) = c_v(l) \end{cases} \\ H_1: \begin{cases} \mathbf{y}(l) = s(l) + c(l) \\ \mathbf{y}_v(l) = c_v(l) \end{cases} \end{cases} \quad (16)$$

其中, $\mathbf{y}(l)$, $\mathbf{y}_v(l)$, $s(l)$, $c(l)$ 分别表示长度为 L 的待检测单元回波、参考单元回波、目标回波和海杂波, V 表示参考单元数目, $l=1, 2, \dots, L$, $v=1, 2, \dots, V$ 。假设海面局部均匀, 那么参考单元的海杂波特性与CUT的海杂波特性应当近似相同, 可利用参考单元海杂波估计局部区域的海杂波特性。

3.3 基于三特征预测的目标检测方法

同一时刻, 同一局部区域的海杂波特性近似相同, 那么局部区域内纯海杂波距离单元提取的AA, RDPH和FPAR特征应分别在同一水平上, 结合海杂波中漂浮小目标检测问题的描述可知, H_0 假设下, 由参考单元估计的局部区域内纯海杂波的AA, RDPH和FPAR特征值, 与CUT的特征观测值差异应当较小, H_1 假设下, 由参考单元估计的局部区域纯海杂波的特征值, 与CUT的特征观测值差异应当较大。

参考单元估计的当前时刻纯海杂波的AA, RDPH和FPAR特征值与待检测单元的AA, RDPH和FPAR特征观测值的差异即为本文所提出的新检测统计量, 即新特征, 可通过式(17)计算, 本文将AA, RDPH和FPAR称为原特征。因为原特征有3种, 故对应的新特征也有3种, 均可通过式(17)计算, 下文以AA特征为例, 说明其对应的新特征如何表征。

$$X_{\text{New}} = |\bar{X} - X_{\text{CUT}}| \quad (17)$$

其中, \bar{X} 为参考单元估计的当前时刻纯海杂波的AA特征值, X_{CUT} 为待检测单元的AA特征观测值, $|\cdot|$ 表示绝对值。 \bar{X} 的具体计算公式如下:

$$\bar{X} = \frac{1}{V} \sum_{v=1}^V X_v \quad (18)$$

其中, V 为参考单元数, X_v 为第 v 个参考单元的当前帧AA特征融合值, 通过式(15)方法计算。显然, \bar{X} 并非参考单元当前帧AA特征观测值的简单平均, 而是融合了所有参考单元当前帧AA特征观测值与特征预测值的加权平均。由于利用了历史帧特征序列的时序信息作为先验信息, 故本文所提特征值估计方法更能反映当前时刻纯海杂波的真实特征值水平。相较于原三特征AA, RDPH和FPAR, 新的三特征利用了原特征的历史帧特征先验信息, 融合了原特征序列的时域演变规律信息, 解决了原特征检测方法对特征序列时域相关性信息利用不足的问题。

3种新特征提取之后, 目标检测问题转化为特征空间中的分类问题, 鉴于目标回波数量远小于纯海杂波, 那么目标检测可看作海杂波中的异常检测, 便可利用单分类器确定一定虚警率条件下的判决区域, 完成检测。目前研究人员已提出大量的单分类器^[24], 本文使用文献^[22]提出的快速凸包单分类器确定判决区域。快速凸包单分类器将给定虚警率下最优判决区域的确定转化为以下最优化问题:

$$\begin{aligned} & \min_{\Omega \in W} \{ \text{Volume}(\Omega) \} \\ & \text{s.t. } \frac{\#\{i: \xi_i \in \Omega\}}{I} = 1 - P_F \\ & W \equiv \{ \text{all bounded convex sets in } R^3 \} \end{aligned} \quad (19)$$

其中, $\#\{\cdot\}$ 表示集合中元素个数, ξ_i 为纯海杂波提取的训练样本, I 为纯海杂波提取的训练样本个数, P_F 为虚警概率, Ω 为满足上述条件的体积最小凸区域。

基于以上论述, 本节提出一种基于三特征预测的海面目标检测器, 主要流程如图8所示。与经典特征检测方法相比, 本文所提目标检测方法, 加入了历史帧特征序列的AR建模和1步预测步骤, 包含训练和检测两部分。雷达正式检测之前, 需要采集大量海杂波数据训练凸包单分类器, 形成判决区域。在训练阶段, 通过大量纯海杂波数据提取AA, RDPH和FPAR特征, 并对特征序列进行AR(p)拟合和1步预测, 进而通过式(15)、式(17)和式(18)生成3种新的特征样本用于训练凸包单分类器, 得到满足给定虚警率条件的判决区域。在检测阶段, 需要从CUT及周围参考单元中提取当前帧的AA, RDPH和FPAR特征, 并对参考单元历史帧窗口内的AA, RDPH和FPAR特征进行AR(p)拟合和1步预测, 通过式(15)、式(17)和式(18)生成CUT的新特征向量, 判断是否在判决空间内, 完成检测。

需要注意的是, 由于本文所使用的AA, RDPH和FPAR特征的分布特性及新特征的计算均与探测场景有关, 故当探测场景变化较大时, 需要重新提取特征、训练凸包分类器和更新判决区域; 为减小计算量及其他参数影响, 历史帧窗口长度固定为 T (每次使用的历史帧特征数量), AR模型阶数固定为 p , 一般AR模型阶数可设为3~7阶; 为增加历史帧与当前帧特征序列的平稳性和相关性, 提升特征序列的AR模型拟合效果和预测效果, 特征提取时, 相邻特征使用的脉冲数据向量可部分重叠, 可通过式(20)划分帧间脉冲。

$$u_j = r(d(j-1) + 1 : d(j-1) + N), j = 1, 2, \dots, T, \dots \quad (20)$$

其中, u_j 为第 j 帧脉冲向量, N 为每帧脉冲数, $r(\cdot)$ 为全部回波脉冲, d 为常数, 用于调整相邻帧的重叠脉冲数。

4 检测性能分析

4.1 实测数据简介

本文所使用的实测数据均来自IPIX雷达数据集, 主要使用1993年采集的10组数据, 每组数据包含HH, VV, HV, VH共4种极化模式数据。数据采

集时, 雷达工作于凝视模式, 凝视时间约131 s, 脉冲重复频率为1 kHz, 距离向分辨率为30 m, 目标为金属丝包裹的直径1 m的漂浮小球^[25], 更详细数据介绍见表2。

4.2 特征空间中的可分性分析

检测器性能可以由对应特征空间中目标样本集 S_1 和海杂波样本集 S_0 之间的可分离性初步判断, 因此首先对其作分析比较。本文采用巴氏距离(Bhattacharyya distance, B-distance)定量衡量两类样本的可分离性, 其估计方法如下:

首先, 计算两类样本集的数学期望向量 μ 和协方差矩阵 C 。

$$\mu_0 = \text{mean}(S_0), C_0 = \text{cov}(S_0) \quad (21)$$

$$\mu_1 = \text{mean}(S_1), C_1 = \text{cov}(S_1) \quad (22)$$

其中, mean表示均值运算符, cov表示协方差运算符。特征空间中两类样本集之间的巴氏距离 d_B 可按式(23)估计。

$$d_B(S_0, S_1) = \frac{1}{4}(\mu_0 - \mu_1)^T(C_0 + C_1)^{-1}(\mu_0 - \mu_1) + \frac{1}{2} \ln \left(\frac{\det(0.5(C_0 + C_1))}{\sqrt{\det(C_0) \det(C_1)}} \right) \quad (23)$$




图 8 基于三特征预测的检测器工作流程图

Fig. 8 The workflow diagram of the detector based on three-feature prediction

表 2 1993年IPIX雷达数据说明

Tab. 2 The description of IPIX radar data collected in 1993

序号	数据名称	浪高(m)	风速(km/h)	目标所在单元	受影响单元
1	#17	2.2	9	9	8, 10, 11
2	#26	1.1	9	7	6, 8
3	#30	0.9	19	7	6, 8
4	#31	0.9	19	7	6, 8, 9
5	#40	1.0	9	7	5, 6, 8
6	#54	0.7	20	8	7, 9, 10
7	#280	1.6	10	8	7, 10
8	#310	0.9	33	7	6, 8, 9
9	#311	0.9	33	7	6, 8, 9
10	#320	0.9	28	7	6, 8, 9

其中， \det 表示行列式运算符。

使用IPIX数据集，初步判断本文所提检测器的性能。从含目标回波单元和纯海杂波单元中分别提取3种新特征，并按照式(21)一式(23)计算巴氏距离，其中经历256个脉冲计算一次AA, RDPH和FPAR特征，相邻特征使用数据存在128个脉冲重叠。同时，本文也计算了原三特征(AA, RDPH和FPAR)空间中两类样本的巴氏距离作为对比，实验结果如图9。可见，新三特征空间中的巴氏距离基本都大于原三特征空间，这预示着本文所提检测器性能优于原三特征检测器，主要原因是新三特征中融合了原三特征的历史帧特征的时序信息，提升了特征所含信息量。

4.3 性能分析

本节进一步测试本文所提基于三特征预测的小目标检测方法的性能。本文所提检测器存在加权系数 α_1, α_2 如何选取的问题，使用10组HH极化的IPIX雷达数据验证二者如何取值。不妨考虑两种极端情形： $\alpha_1=1, \alpha_2=0$ 与 $\alpha_1=0, \alpha_2=1$ 。当 $\alpha_1=1, \alpha_2=0$ 时，新特征中不含原特征的历史帧特征信息；当 $\alpha_1=0, \alpha_2=1$ 时，新特征受原特征的历史帧特征信息影响最大。本文所提检测器在这两种情形下的检测

概率曲线如图10所示，实验过程中，256个脉冲计算一次AA, RDPH和FPAR特征。可见，整体而言，两种情形下的检测概率相差不大，这表明当前帧特征值与历史帧特征值对检测概率的贡献应当大致相同，因此IPIX雷达数据加权系数 α_1, α_2 的经验值均为0.5。

利用#30, #31和#310数据比较相邻特征使用的重叠脉冲数分别为0, 64, 128时，本文所提检测器的性能变化，其中计算AA, RDPH和FPAR特征的脉冲数固定为256，实验结果如表3所示。可见，大部分数据集中，随着重叠脉冲数的增加，检测器检测概率逐渐增加，主要原因是随着相邻特征使用数据重叠脉冲数的增加，特征序列更加平稳，AR模型拟合和预测效果更好。

利用#30, #31和#310数据比较历史帧窗口长度分别为25, 50, 100时，本文所提检测器的性能变化，其中计算AA, RDPH和FPAR特征的脉冲数固定为256，实验结果如表4所示。可见，大部分数据集中，随着历史帧窗口长度的增加，检测器检测概率逐渐增加，主要原因是历史帧窗口长度越大，单次AR建模使用特征数越多，AR模型参数估计越准确，1步预测准确度越高；相较于重叠脉冲数，历

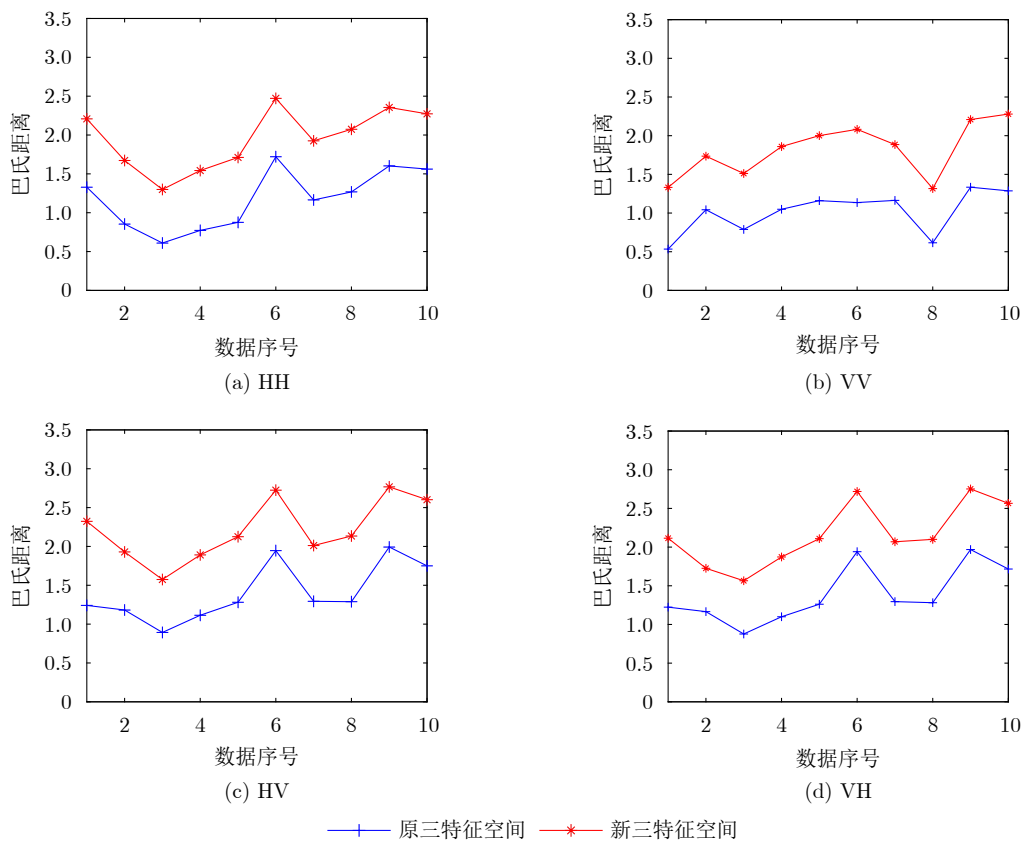


图9 两种特征空间内的巴氏距离对比

Fig. 9 Comparison of B-distance in two feature spaces

史帧窗口长度对检测概率的影响很小，主要原因是其对1步预测准确度影响较小，一般情况下，历史帧窗口长度可设为50。

使用全部IPIX雷达数据，验证本文所提检测器的有效性，实验过程中，256个脉冲计算一次AA, RDPH和FPAR特征，相邻特征使用的脉冲数据存在128个脉冲重叠。为比较分析，本文使用基于AA, RDPH和FPAR的原三特征检测器，时域、多普勒域三特征检测器^[22]及散斑一致性因子检测器^[26]进行了对比实验，计算单个特征所使用脉冲数均为256。相较于本文所提方法，基于AA, RDPH和FPAR的三特征检测器直接使用AA, RDPH和FPAR特征训练凸包分类器进行检测，是本文所提检测算法的原特征检测方法。文献^[22]提出的检测器使用一种时域幅度特征和两种多普勒谱特征进行检测，一致性因子检测器根据海杂波中的散斑分量和目标回波的平稳性差异特征进行检测。

图11给出了4种检测器在4种极化数据上的检测




图 10 加权系数对检测概率的影响

Fig. 10 The effect of weighting coefficient on detection probabilities

概率曲线，虚警概率 $P_F = 0.001$ 。显然，相较于单特征检测器，三特征检测器检测概率提升明显，主要原因是单一特征难以应对所有探测场景，使用更多区分效果更好的特征，是提升检测器性能稳定性的重要思路。大部分数据集中，本文所提检测器在4种检测器中效果都能达到最佳。相较于原三特征检测器，本文所提检测器的检测性能提升较大，主要原因是相较于原三特征检测器，所提检测器利用了原三特征的历史帧特征数据的时序信息，解决了原特征检测方法对先验信息利用不足的问题，提升了特征所含信息量。从图11结果也能看出，当原三特征检测器的正确检测概率较低时，本文所提方法的检测概率提升较大，当原三特征检测器的正确检测概率较高时，本文所提方法的检测概率提升较小。主要原因有两点，一是原三特征检测方法检测概率较低时，数据集的SCR一般较低，海杂波的AA, RDPH和FPAR特征存在较多“异常值”，本文所提方法利用历史帧特征先验信息对其进行了修正，而原三特征检测方法检测概率较高时，数据集的SCR一般较高，海杂波的AA, RDPH和FPAR特征“异常值”较少，此时本文所提方法对其修正有限；二是门限效应的影响。

改变提取AA, RDPH和FPAR特征所使用的脉冲数，脉冲数为128时，相邻特征使用的脉冲数据存在64个脉冲重叠；脉冲数为512时，相邻特征使用的脉冲数据存在256个脉冲重叠，其余参数不变，实验结果如表5所示。可知，大多数情况下，本文所提检测器在4种检测器中效果都能达到最佳；在3种脉冲数条件下，本文所提检测器对原三特征检测器的性能均有改善。

表 3 重叠脉冲数对本文所提检测器的影响

Tab. 3 The effect of the number of overlapping pulses on the detector proposed in this paper

重叠脉冲数	#30			#31			#310		
	HH	VV	HV	HH	VV	HV	HH	VV	HV
0	0.270	0.381	0.417	0.316	0.519	0.541	0.573	0.255	0.604
64	0.281	0.371	0.369	0.324	0.535	0.574	0.596	0.289	0.597
128	0.345	0.457	0.485	0.412	0.578	0.637	0.602	0.310	0.649

表 4 历史帧窗口长度对本文所提检测器的影响

Tab. 4 The effect of historical frame window length on the detector proposed in this paper

历史帧窗口长度	#30			#31			#310		
	HH	VV	HV	HH	VV	HV	HH	VV	HV
25	0.304	0.433	0.435	0.396	0.539	0.628	0.600	0.305	0.641
50	0.317	0.446	0.462	0.400	0.561	0.635	0.602	0.312	0.647
100	0.345	0.457	0.485	0.412	0.578	0.637	0.602	0.310	0.649

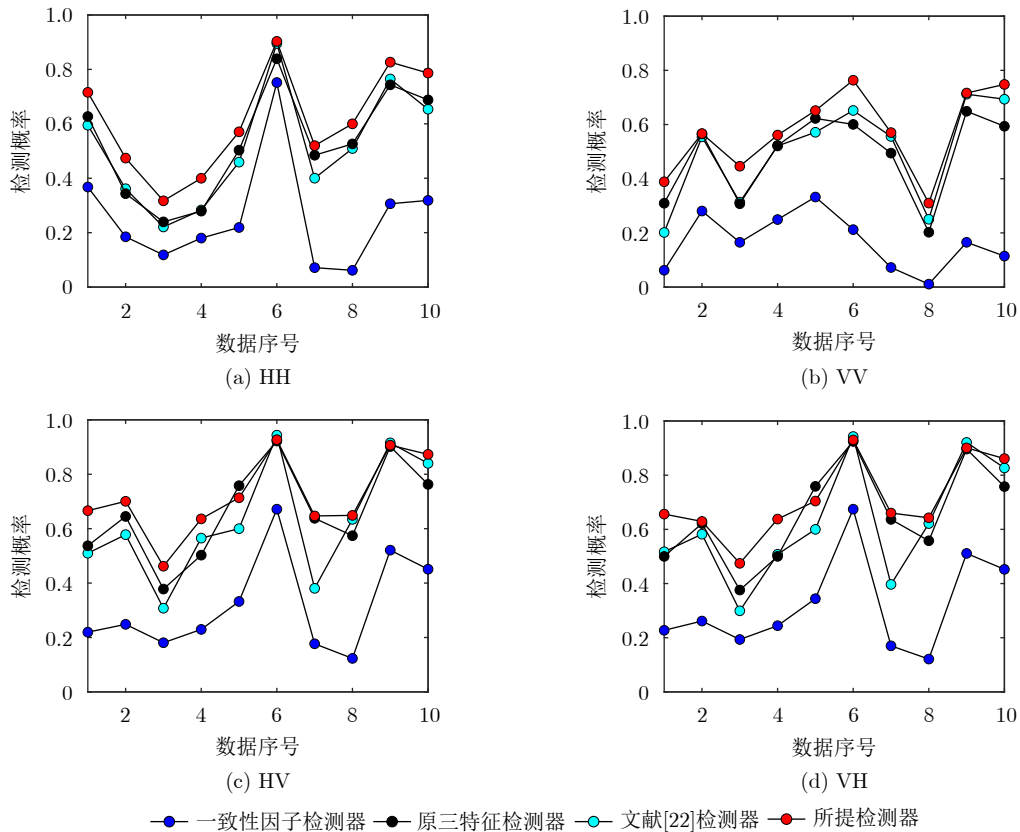


图 11 4种检测器的检测概率

Fig. 11 Detection probabilities of the four detectors

表 5 脉冲数对4种检测器的影响

Tab. 5 The effect of the number of pulses on the four detectors

脉冲数	检测器	#17			#26			#320		
		HH	VV	HV	HH	VV	HV	HH	VV	HV
128	一致性因子检测器 ^[26]	0.272	0.035	0.214	0.151	0.234	0.200	0.363	0.108	0.469
	文献[22]检测器	0.521	0.237	0.544	0.286	0.366	0.473	0.553	0.556	0.825
	原三特征检测器	0.595	0.257	0.509	0.211	0.389	0.466	0.628	0.487	0.754
	所提检测器	0.642	0.304	0.544	0.281	0.403	0.528	0.745	0.674	0.855
256	一致性因子检测器 ^[26]	0.368	0.062	0.220	0.185	0.281	0.249	0.319	0.115	0.461
	文献[22]检测器	0.595	0.202	0.510	0.361	0.555	0.578	0.654	0.693	0.840
	原三特征检测器	0.627	0.310	0.537	0.343	0.565	0.645	0.688	0.594	0.763
	所提检测器	0.716	0.389	0.666	0.474	0.567	0.701	0.787	0.748	0.873
512	一致性因子检测器 ^[26]	0.345	0.058	0.215	0.200	0.314	0.263	0.221	0.121	0.470
	文献[22]检测器	0.621	0.201	0.521	0.441	0.581	0.590	0.758	0.764	0.855
	原三特征检测器	0.633	0.353	0.620	0.425	0.613	0.686	0.657	0.625	0.845
	所提检测器	0.731	0.428	0.792	0.544	0.620	0.747	0.803	0.783	0.908

5 结语

本文提出了一种使用AR模型在特征域对雷达回波进行时序建模和预测的方法，以利用历史帧特征先验信息，并在此基础上形成了新的特征用于检测。本文主要有两个创新点：一是使用AR模型对

AA, RDPH和FPAR特征序列进行建模。实测数据分析表明，基于AR模型，可以很好地实现AA, RDPH和FPAR特征序列的拟合和1步预测。二是提出利用历史帧特征时序信息作为先验信息的特征值提取方法，并在此基础上，提出一种改进的基于

三特征(AA, RDPH和FPAR)预测的海杂波中目标检测方法。对比实验结果表明,相较于原三特征检测方法,本文所提基于三特征预测的小目标检测方法的性能提升明显,有效地解决了原特征检测方法对帧间特征时序信息利用不足的问题。

参 考 文 献

- [1] 关键. 雷达海上目标特性综述[J]. 雷达学报, 2020, 9(4): 674–683. doi: [10.12000/JR20114](https://doi.org/10.12000/JR20114).
GUAN Jian. Summary of marine radar target characteristics[J]. *Journal of Radars*, 2020, 9(4): 674–683. doi: [10.12000/JR20114](https://doi.org/10.12000/JR20114).
- [2] 张坤, 水鹏朗, 王光辉. 相参雷达K分布海杂波背景下非相干积累恒虚警检测方法[J]. 电子与信息学报, 2020, 42(7): 1627–1635. doi: [10.11999/JEIT190441](https://doi.org/10.11999/JEIT190441).
ZHANG Kun, SHUI Penglang, and WANG Guanghui. Non-coherent integration constant false alarm rate detectors against k-distributed sea clutter for coherent radar systems[J]. *Journal of Electronics & Information Technology*, 2020, 42(7): 1627–1635. doi: [10.11999/JEIT190441](https://doi.org/10.11999/JEIT190441).
- [3] 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. doi: [10.12000/JR20084](https://doi.org/10.12000/JR20084).
XU Shuwen, BAI Xiaohui, GUO Zixun, 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. doi: [10.12000/JR20084](https://doi.org/10.12000/JR20084).
- [4] LO T, LEUNG H, LITVA J, et al. Fractal characterisation of sea-scattered signals and detection of sea-surface targets[J]. *IEE Proceedings F-Radar and Signal Processing*, 1993, 140(4): 243–250. doi: [10.1049/ip-f-2.1993.0034](https://doi.org/10.1049/ip-f-2.1993.0034).
- [5] FAN Yifei, TAO Mingliang, and SU Jia. Multifractal correlation analysis of autoregressive spectrum-based feature learning for target detection within sea clutter[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5108811. doi: [10.1109/TGRS.2021.3137466](https://doi.org/10.1109/TGRS.2021.3137466).
- [6] FAN Yifei, TAO Mingliang, SU Jia, et al. Weak target detection based on joint fractal characteristics of autoregressive spectrum in sea clutter background[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(12): 1824–1828. doi: [10.1109/LGRS.2019.2912329](https://doi.org/10.1109/LGRS.2019.2912329).
- [7] BI Xiaowen, GUO Shenglong, YANG Yunxiu, et al. Adaptive target extraction method in sea clutter based on fractional fourier filtering[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5115609. doi: [10.1109/TGRS.2022.3192893](https://doi.org/10.1109/TGRS.2022.3192893).
- [8] SHI Sainan and SHUI Penglang. 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. doi: [10.1109/TGRS.2018.2838260](https://doi.org/10.1109/TGRS.2018.2838260).
- [9] XU Shuwen, ZHENG Jibin, PU Jia, et al. Sea-surface floating small target detection based on polarization features[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(10): 1505–1509. doi: [10.1109/LGRS.2018.2852560](https://doi.org/10.1109/LGRS.2018.2852560).
- [10] 陈世超, 高鹤婷, 罗丰. 基于极化联合特征的海面目标检测方法[J]. 雷达学报, 2020, 9(4): 664–673. doi: [10.12000/JR20072](https://doi.org/10.12000/JR20072).
CHEN Shichao, GAO Heting, and LUO Feng. Target detection in sea clutter based on combined characteristics of polarization[J]. *Journal of Radars*, 2020, 9(4): 664–673. doi: [10.12000/JR20072](https://doi.org/10.12000/JR20072).
- [11] YAN Kun, BAI Yu, WU H C, et al. Robust target detection within sea clutter based on graphs[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(9): 7093–7103. doi: [10.1109/TGRS.2019.2911451](https://doi.org/10.1109/TGRS.2019.2911451).
- [12] 时艳玲, 姚婷婷, 郭亚星. 基于图连通密度的海面漂浮小目标检测[J]. 电子与信息学报, 2021, 43(11): 3185–3192. doi: [10.11999/JEIT201028](https://doi.org/10.11999/JEIT201028).
SHI Yanling, YAO Tingting, and GUO Yaxing. Floating small target detection based on graph connected density in sea surface[J]. *Journal of Electronics & Information Technology*, 2021, 43(11): 3185–3192. doi: [10.11999/JEIT201028](https://doi.org/10.11999/JEIT201028).
- [13] XIE Jianda and XU Xiaojian. Phase-feature-based detection of small targets in sea clutter[J]. *IEEE Geoscience and Remote Sensing Letters*, 2022, 19: 3507405. doi: [10.1109/LGRS.2021.3093620](https://doi.org/10.1109/LGRS.2021.3093620).
- [14] WU Xijie, DING Hao, LIU Ningbo, et al. A method for detecting small targets in sea surface based on singular spectrum analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5110817. doi: [10.1109/TGRS.2021.3138488](https://doi.org/10.1109/TGRS.2021.3138488).
- [15] 关键, 伍偲杰, 丁昊, 等. 基于对角积分双谱的海面慢速小目标检测方法[J]. 电子与信息学报, 2022, 44(7): 2449–2460. doi: [10.11999/JEIT210408](https://doi.org/10.11999/JEIT210408).
GUAN Jian, WU Xijie, DING Hao, et al. A method for detecting small slow targets in sea surface based on diagonal integrated bispectrum[J]. *Journal of Electronics & Information Technology*, 2022, 44(7): 2449–2460. doi: [10.11999/JEIT210408](https://doi.org/10.11999/JEIT210408).
- [16] WU Xijie, DING Hao, LIU Ningbo, et al. Priori information-based feature extraction method for small target detection in sea clutter[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5115315. doi: [10.1109/TGRS.2022.3188046](https://doi.org/10.1109/TGRS.2022.3188046).
- [17] HAYKIN S, BAKKER R, and CURRIE B W. Uncovering

- nonlinear dynamics-the case study of sea clutter[J]. *Proceedings of the IEEE*, 2002, 90(5): 860–881. doi: [10.1109/JPROC.2002.1015011](https://doi.org/10.1109/JPROC.2002.1015011).
- [18] NOHARA T J and HAYKIN S. AR-based growler detection in sea clutter[J]. *IEEE Transactions on Signal Processing*, 1993, 41(3): 1259–1271. doi: [10.1109/78.205728](https://doi.org/10.1109/78.205728).
- [19] 黄红梅. 应用时间序列分析[M]. 北京: 清华大学出版社, 2016: 17–57.
HUANG Hongmei. Apply Time Series Analysis[M]. Beijing: Tsinghua University Press, 2016: 17–57.
- [20] 郑宁. 基于多源数据的高速铁路轨道几何异常状态检测方法研究[D]. [硕士学位论文], 北京交通大学, 2021: 22–40. doi: [10.26944/d.cnki.gbfju.2021.003635](https://doi.org/10.26944/d.cnki.gbfju.2021.003635).
ZHENG Ning. Research on high speed railway track geometric anomaly detection method based on multi-source data[D]. [Master dissertation], Beijing Jiaotong University, 2021: 22–40. doi: [10.26944/d.cnki.gbfju.2021.003635](https://doi.org/10.26944/d.cnki.gbfju.2021.003635).
- [21] 范剑青, 姚琦伟, 陈敏, 译. 非线性时间序列: 建模、预报及应用[M]. 北京: 高等教育出版社, 2005: 21–92.
FAN Jianqing, YAO Qiwei, CHEN Min. translation. Nonlinear Time Series: Modeling, Forecasting, and Applications[M]. Beijing: Higher Education Press, 2005: 21–92.
- [22] SHUI Penglang, LI Dongchen, and XU Shuwen. Tri-feature-based detection of floating small targets in sea clutter[J]. *IEEE Transactions on Aerospace & Electronic Systems*, 2014, 50(2): 1416–1430. doi: [10.1109/TAES.2014.120657](https://doi.org/10.1109/TAES.2014.120657).
- [23] LI Yuzhou, XIE Pengcheng, TANG Zeshen, et al. SVM-based sea-surface small target detection: A false-alarm-rate-controllable approach[J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(8): 1225–1229. doi: [10.1109/LGRS.2019.2894385](https://doi.org/10.1109/LGRS.2019.2894385).
- [24] GUO Zixun and SHUI Penglang. Anomaly based sea-surface small target detection using K-nearest neighbor classification[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2020, 56(6): 4947–4964. doi: [10.1109/TAES.2020.3011868](https://doi.org/10.1109/TAES.2020.3011868).
- [25] The IPIX radar database[EB/OL]. <http://soma.ece.mcmaster.ca/ipix/>, 2021.
- [26] SHI Yanling, XIE Xiaoyan, and LI Dongchen. Range distributed floating target detection in sea clutter via feature-based detector[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(12): 1847–1850. doi: [10.1109/LGRS.2016.2614750](https://doi.org/10.1109/LGRS.2016.2614750).

作者简介

董云龙, 博士, 教授, 主要研究方向为多传感器信息融合、雷达目标检测与跟踪。

张兆祥, 硕士生, 主要研究方向为海杂波中目标检测。

丁昊, 博士, 副教授, 主要研究方向为海杂波特性认知与抑制、海杂波中目标检测。

黄勇, 博士, 副教授, 主要研究方向为雷达目标检测、MIMO雷达信号处理。

刘宁波, 博士, 副教授, 主要研究方向为雷达信号智能处理、海上目标探测技术。

(责任编辑: 高山流水)