

DOI:10.19651/j.cnki.emt.1802251

海杂波背景下的 PSO-RBF 弱目标检测

石嘉 夏德平

(南京电子技术研究所 南京 210000)

摘要: 海杂波背景下的目标检测是海面雷达信号处理的重要组成部分。海杂波中弱目标的检测,传统方法是基于海杂波统计特性,但是统计特性并不能很好地反映海杂波的内在动力学特性,因此检测效果很不理想。本文根据海杂波的混沌特性,对其进行了相空间重构,并将粒子群算法(PSO)应用到径向基函数(RBF)神经网络核函数参数的优化学习中,利用加拿大 McMaster 大学采用 IPIX 雷达在 Dartmouth 地区海域实测带有目标的海杂波数据对此方法进行验证。结果表明,在混沌海杂波背景下 PSO-RBF 小目标检测法具有良好的预测性,相比于一般的径向基神经网络,改进算法不仅收敛速度快,且误差精度高。

关键词: 粒子群优化;径向基函数;目标检测;神经网络;海杂波

中图分类号: TP951 **文献标识码:** A **国家标准学科分类代码:** 510.105

PSO-RBF small target detection based on sea clutter

Shi Jia Xia Deping

(Nanjing Research Institute of Electronic and Technology, Nanjing 210000, China)

Abstract: Target detection in the background of sea clutter is an important part of sea surface radar signal processing. The detection of weak targets in sea clutter is based on the statistical characteristics of sea clutter, but the statistical persistence does not reflect the intrinsic dynamics of sea clutter. Therefore, the detection results are not ideal. Based on the chaotic characteristics of sea clutter, this dissertation reconstructs the phase space of the sea clutter, and particle swarm optimization (PSO) is applied to radial basis function(RBF) neural network kernel function parameters. In the optimization study, this method is validated by using IPIX radar to measure sea clutter with target in Dartmouth area. The results show that: PSO-RBF small target detection method has good predictability in the background of chaotic sea clutter. Compared with the general radial basis neural network, the improved algorithm not only has fast convergence speed but also has high recognition rate.

Keywords: particle swarm optimization (PSO); radial basis function (RBF); target detection; neural network; sea clutter

0 引言

近几年,海平面群目标检测技术及应用受到广泛关注。海水杂散波是雷达信号传输至海平面的反馈信号,由于信号属于电磁波的一种,容易受到外界海浪、风速及风力等外部环境的影响。海面杂散波形对于海面上目标观测的影响较大,容易造成较大的观测误差值,不利于海上及海面低空目标物的精确观测,因此,深入研究和分析海面杂散波的特性对于雷达探测工程具有重要意义。

检测海平面及低空位置的目标的难度主要集中在外部海面杂散波形的影响及干扰。考虑到海面杂散波形的波形特点与噪音波类似,传统的海面杂散波形检测主要借助于波形建模并配合数理统计分析技术,根据建立的统计学模

型进行假设检验。以往的海面杂散波形检测方式是在固定时域及频域内的信号变化幅度进行建模计算^[1]。综上,海面杂散波的检测精度与波形信号的信噪比联系紧密。但应注意的是,在外部噪音水平较低的环境中,难以获取最佳的检测效果。

雷达工程研究专家 Haykin 等^[2]借助精密测量技术,对检测到的海面杂散波形相关数据进行反复测算和分析,得到海面杂散波形的混沌性基本特点,可以实现量化统计和分析。上述结论一经提出,部分学者将人工神经网络技术及非线性相关理论引入海面目标的监测中,目标监测的效率显著提升。Leung 等^[3]采用遗传学优化理论,得到相应的 RBFNN 中心点、均方差值及隐含层的节点参数,通过最

小二乘法确定各权重值,得到最优解条件下的海面杂散波形计算参数,径向基函数(radial basis function, RBF)的接近误差显著降低。国内王福友^[4]在分析基于归一化的人工神经网络分析技术及小二乘法向量下的非线性预测技术基础上,提出了最小乘支持向量机-耦合映像格子预测技术。行鸿彦等^[5]借助耦合边界条件下的最小二乘支持向量算法对混沌条件下的海面杂散波形中蕴藏的微弱信号进行检测监测。

本文借助空间重构技术对海面杂散波形进行分析^[6-8],基于该算法提出了满足自适应条件及能力的权值变动及局部区域搜索粒子群优化(particle swarm optimization, PSO)算法^[7]。上述算法适用于人工神经网络计算中的核心函数及参数最优化学习。仿真计算结果表明,PSO-RBF算法^[9-13]在基于混沌环境背景下的海面杂散波形预测精度较高,同传统的径向神经网络算法相比,改进后的优化算法计算收敛性能好,计算精度高。

1 PSO-RBF 神经网络目标检测

1.1 相空间重构

海面杂散波形的空间重构的分析初衷是为了将传统的一维时间序列里的波形数据信息排列到多维空间结构中,以便于后续继续深入分析。早在 20 世纪 80 年代初期, Takens^[14]首次提出了基于 Takens 的嵌入式数据分析基本理论,并论述了从单一变量向多重混沌环境下的奇异吸引子相互空间的可行性。在敏感性计算过程中,采用微分计算法,通过坐标延迟分析法实现重空间体系的重构,上述计算的本质就是在在一维时间序列内建立 m 维空间的矢量表达式如下:

$$y(t+m\tau) = F(y(t), y(t+\tau), \dots, y(t+(m-1)\tau)) \quad (1)$$

式中: m 表示嵌入式计算的维度; τ 表示延迟计算时间值, F 表示非线性函数表达式。坐标计算过程中涉及到的空间重构延迟计算流程如下:

1) 对于数据嵌入分析的延迟计算。相关性函数计算是常用的简化计算方法之一,且也是目前相对成熟的计算方式之一。在一个整体的时间区间 $y(t)$, 对印尼的时间相关性函数如下:

$$R(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T}^{+T} y(t)y(t+\tau)dt \quad (2)$$

式中: τ 表示时间延迟特征; T 表示一个整体变量内的周期。根据相应的时间周期 T 内,选定一定的时间间隔作为采样间距,对数据信息进行离散化,得到 $x(t)$ 对应的时间相关性函数,具体表达式如下:

$$R_{xx}(\tau) = \frac{1}{N} \sum_{t=0}^{N-1} x(t)x(t+\tau) \quad (3)$$

绘制相应的相关性函数表达式 $R_{xx}(\tau)$ 与对应的时间延迟特性 τ 之间的函数关系曲线,若 $R_{xx}(\tau)$ 的计算结果降

低至 $R_{xx}(0)$ 的 $\frac{e-1}{e}$ 时,计算得到的 τ 即表示最合理的数据嵌入延时。

2) 嵌入对应的数据维度特征值。GP 计算方法常用的嵌入维度系数值计算较为简便,却是相对成熟的计算方式之一。在任意一个对应的 n 个 m 维度空间中,相应的关联度计算公式如下:

$$D_c = \lim_{r \rightarrow 0} \left\{ \frac{\ln(A_r)}{\ln(r)} \right\} \quad (4)$$

$$A_r = \lim_{n \rightarrow \infty} \left\{ \frac{s}{n^3} \right\} \quad (5)$$

式中: r 表示计算得出的距离值; s 为点之间的距离值低于 r 的全部点数的和。

假定在某个一维的时间序列空间中,对应的的时间序列如下: $\{x(t); t = 1, 2, \dots, N\}$, 可以采用 $\{x(t)\}$ 重构 m 维的数据空间,基于 Takens 数据嵌入分析原理,可以得到相应的空间向量表达式如下:

$$\mathbf{X}(t) = \{x(t), x(t+\tau), \dots, x(t+(m-1)\tau)\} \quad (6)$$

式中: τ 为对应的延时嵌入情况; m 为对应的嵌入维度; $M = N - (m-1)\tau$ 为对应的空间内的中间点的总和,相应的关联积分值计算公式如下:

$$C_n(r) = \frac{1}{M^2} \sum_{i,j=1}^M \theta[r - \|\mathbf{X}(i) - \mathbf{X}(j)\|] \quad (7)$$

式中: r 为正数; θ 为 Heaviside 函数。对应的关联维度系数值如下:

$$D = \log C_n(r) / \log r \quad (8)$$

为了量化计算关联函数的维度,应先绘制相应的关联积分表达式 $C_n(r)$ 与 r 之间对应的对数关系图。对 $\log C_n(r) \sim \log r$ 的直线性拟合情况,经数据拟合得到的直线斜率值称为对应的关联系数指数值。其中,嵌入数据维度与关联指数值呈现显著的正相关关系,但是,一旦关联系数值趋向于饱和时,相应的关联系数嵌入维度指标是对应的最小嵌入维度系数。

综上所述,应先对海面杂散波形的监测数据建立相应的相关性函数,借助 GP 算法得到相应的延时嵌入值 τ 和相应的嵌入维度数 m 即实现对海面杂散波相关数据的空间重构。

1.2 粒子群优化算法的基本原理

基于粒子群优化的模拟计算法的计算灵感来自于鸟群觅食,借助粒子群之间的相互协作方式,实现全区域内的数据搜集。其中,PSO 算法的数据迭代过程中的计算必须至少对 2 个及以上的数据进行快速跟踪及定位。其中, 2 个极值分别为对应的个体极值 p_{best} 和全局极值 g_{best} 。

假定在一个整体的 D 维空间内进行数据搜索,有共计 N 个粒子构成一个整体的群体,其中,第 i 个对应的粒子表示相应的 D 维向量表达式,具体表达式如下:

$$\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD}), i = 1, 2, \dots, N \quad (9)$$

第 i 个粒子群飞行的速率,也表示相应的 D 维向量值,计算公式如下:

$$\mathbf{V}_i = (v_{i1}, v_{i2}, \dots, v_{iD}), i = 1, 2, \dots, N \quad (10)$$

第 i 个粒子是目前为止可以获取的最佳的位置对应的个体极值,具体如下:

$$\mathbf{P}_i = (p_{i1}, p_{i2}, \dots, p_{iD}), i = 1, 2, \dots, N \quad (11)$$

整个粒子群中截止目前搜索的最佳的位置下的全局极值,具体如下:

$$g_{\text{best}} = (p_{g1}, p_{g2}, \dots, p_{gD}) \quad (12)$$

在上述获取的两个最优值中,粒子群的计算公式如式(13)和(14)记录的位置及速率所示:

$$v_{id}^{k+1} = v_{id}^k + c_1 \text{rand}() (p_i^k - x_{id}^k) + c_2 \text{rand}() (p_{gd}^k - x_{id}^k) \quad (13)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (14)$$

式中: c_1 和 c_2 为相应的学习因素; v_{id} 为粒子群中粒子的运行速率, $v_{id} \in [-v_{\text{max}}, v_{\text{max}}]$, v_{max} 为常数,主要由用户提前设定的粒子群速率 $\text{rand}()$ 表示,其值介于 $[0, 1]$ 范围内的随机数值。

本文提及的 PSO 算法是在式(13)的迭代计算中添加时变权重 w_i , 上述计算方式可以确保粒子群运行过程中的数据采集及搜索能力,伴随迭代计算次数的增加,在粒子群飞行的后期,可以提升数据及算法的采集及数据开发能力。在迭代计算式(14)中添加相应的局部的数据搜索因子 α , 提及的局部数据搜索因子主要是针对于粒子群在数据更新后,相应的数据更新范围内的随机搜索,例如,搜索对应的新位置比之前的位置优化程度更高,因此,相应的计算位置额可以视为下一个计算及进化的起始点。相应的数学计算描述方式如下:

$$v_{id}^{k+1} = v_{id}^k + c_1 \text{rand}() (p_i^k - x_{id}^k) + c_2 \text{rand}() (p_{gd}^k - x_{id}^k) = \left\{ w_{\text{end}} + (w_{\text{start}} - w_{\text{end}}) \exp \left[-15 \left(\frac{k}{k_{\text{max}}} \right)^3 \right] \right\} v_{id}^k + c_1 \text{rand}() (p_i^k - x_{id}^k) + c_2 \text{rand}() (p_{gd}^k - x_{id}^k) \quad (15)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \alpha = x_{id}^k + v_{id}^{k+1} \text{rand}() \theta \quad (16)$$

式中: w_i 对应的数据选取范围介于 $(w_{\text{min}}, w_{\text{max}})$; k_{max} 表示计算过程中的最大迭代次数; $\text{rand}()$ 介于 $[0, 1]$ 范围内的随机数; $\theta = [\text{rand}() + 0.5]$ ($[]$ 表示取整计算)。

1.3 RBF 神经网络结构

RBF 神经网络分析法是基于函数逼近理论的函数传播网络反馈重构技术,其具备较强的类型划分及数据的非线性逼近能力。其中,RBF 神经网络分析结构如图 1 所示。




图 1 RBF 神经网络结构分析图

分析图 1 可知,基于 RBF 的人工神经网络结构的形式为 3 层。其中,从数据输入层至数据输出层中保护数据隐含层,隐含层主要功能是数据输入层与数据输出层之间的相互联系。设定网络数据输入层集合为: $\mathbf{X} \in \mathbf{R}^n = \{x_1, x_2, \dots, x_p\}$, 相应的隐含单元层中 Z_i 表示数据输出层相应的集合为 $Z_i = R_i(\|\mathbf{X} - \mathbf{c}_i\|)$, 其中, R_i 表示径向基函数,通常取用 n 维高斯函数表达式:

$$R_i(\|\mathbf{X} - \mathbf{c}_i\|) = \exp\left(-\frac{\|\mathbf{X} - \mathbf{c}_i\|^2}{\sigma_i^2}\right) \quad (17)$$

式中: \mathbf{X} 表示维的向量输入结果; \mathbf{c}_i 为第 i 个基础函数对应的中心位置; σ_i 为第 i 个基础函数对应的数据带宽;值 $\|\cdot\|$ 为欧拉范数。其中,RBF 神经网络的数据输出值为:

$Y = \sum_{i=1}^k W_i Z_i$, Y 表示数据输出结果; W_i 为 Z_i 对应的函数权重。

内核函数的选定必须以 RBF 人工神经网络的训练结果为基础。通常情况下,K 均值算法、k-means 方法等均依赖于中心的选定,但是,在具体计算过程中易于陷入局部范围内的最优解。所以,本文选定基于改进优化的 PSO 算法,并将其应用至 RBF 神经网络计算实践中,以提升计算精确度、收敛性及计算效率。PSO-RBF 神经网络流程如图 2 所示。

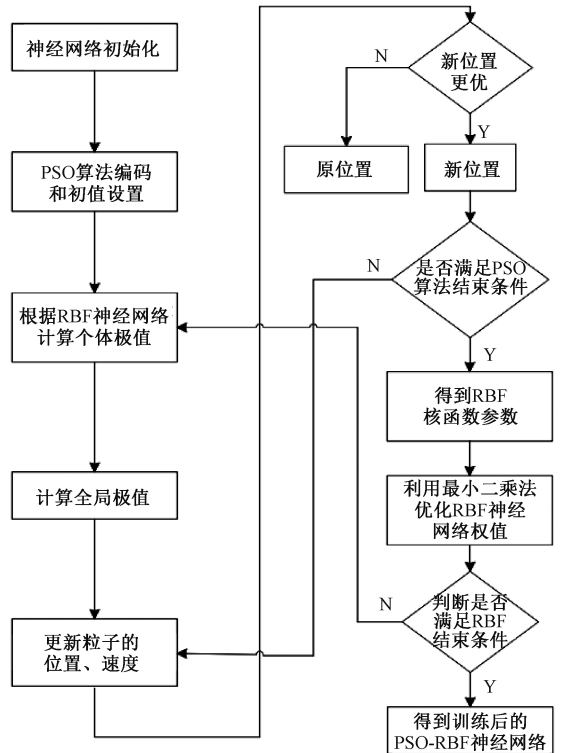


图 2 PSO-RBF 神经网络计算训练环节

1.4 PSO-RBF 算法的训练步骤

神经网络训练完成后,对采集到的数据信息进行

同步预判,得到相应的预估值 \hat{x}_n , 通过计算方式消除计算误差及均方差误差值。误差计算表达式如下:

$$E = \hat{x}_n - x_n \quad (18)$$

总误差的均方差值:

$$R = \frac{1}{n} \sqrt{\sum_{n=1}^n (\hat{x}_n - x_n)^2} \quad (19)$$

2 实验仿真及结果过分析

2.1 模拟海杂波预测

假定在混沌体系背景下,对海面的杂散波形及噪音的反馈波形 $s(n)$ 进行量化分析及刻画。

$$\begin{cases} H_0: x(n) = c(n), 1 \leq n \leq N_T \\ H_1: x(n) = s(n) + c(n), 1 \leq n \leq N_T \end{cases} \quad (20)$$

式中: $x(n)$ 表示观测周期内的时间顺序; $c(n)$ 表示混沌背景下的信号值; $s(n)$ 表示目标信号参数; N_T 表示观测周期内的信号总点位数; H_0 表示尚不存在相应的目标信号值; H_1 表示目标信号存在。

本文选定洛伦兹周期序列模拟海面杂散波形,波形相关关键参数如下: $\sigma = 16, b = 4, r = 45.92$ 。表达式的初始值取值如下: $x = -1, y = 0, z = 1$, 选定积分运算的步长为 0.01 的 4 阶 Runger-Kutta 的方法^[14+15] 求解 Lorenz 方程。采集到计算方程中得到的 x 分量数据采集信号作为混沌分析的背景信号参数。若系统处于完全的混沌状态下,使用 Cao 方法求解相应的数据嵌入维度系数值 $m = 5$, 相互信息量得到的延迟实现参数值 $\tau = 1$ 。选定研究样本的容量值为 1 500 个,并选用数据样本中的参数对人工改进优化后的 PSO-RBF 神经网络进行持续训练,基于混沌背景特性下的目标检测信号表达式如下:

$$s(n) = 0.01 \sin(2\pi f n), f = 0.3 \quad (21)$$

单一周期内的信号 $s(n)$ 对应的频率波谱图如图 3 所示,得到波形信号的信噪比为 -75.98 dB。先对混沌背景下的时间序列进行重构,并使用改进后的人工 PSO-RBF 神经网络实现单步长预判,相应的预判结果如图 4 所示。对相应的单步长误差预测结果进行傅里叶变换,得到基于频域下的波谱图,如图 5 所示。

分析图 5 可知,优化后的人工 PSO-RBF 神经网络对包含矩形波形信号对应的混沌时间序列内的数据进行预测,得到的预测误差结果经傅里叶变换后得到的频率 $f = 0.3$ 在对应位置的误差值偏差值较大,剩余点的误差值较小。信号预测结果对应的 RMSE 值和相应的训练时间如表 1 所示。

表 1 三种算法在仿真中的性能比较

算法	RBF	标准 PSO-RBF	优化后的 PSO-RBF
神经网络训练周期/s	883.6	678.2	258.5
RMSE 值	0.032	0.183	0.000 323




图 3 单个周期信号频谱图




图 4 含单个周期信号的混沌时间序列预测值与真实值




图 5 单个周期信号单步预测误差频谱

分析表 1 可知,本文选用的预测方式及相关的训练时间及预判能力显著提升。

2.2 实测海杂波预测

将实际监测到的海面杂散波形数据集 $x(n)$, 在混沌背景下的优化后的人工 PSO-RBF 神经网络预判误差值的较弱目标的检测方式及相关环节如下:

1) 基于相互信息量法及 Cao 方法得到对应的延迟时间 τ 及最合理的嵌入维度系数值 m , 对实际监测数据中海面杂散波形的时间序列进行空间重构。

2) 考虑到实际监测到的海面杂散波形的参数值具有显著的周期性及可预判性,因此,对优化的人工 PSO-RBF 神经网络可以先选定一组不含有弱小目标的海面杂散波形相关数据进行系统训练。

3) 采用训练完成的人工优化 PSO-RBF 神经网络实现对海面杂散波形相关数据 $x(n)$ 在单一步长内的预判, 得到相应的预判值 $\hat{x}(n)$, RMSE 计算公式为:

$$R = \frac{1}{n} \sqrt{\sum_n^{i=1} (\hat{x}(n) - x(n))^2} \quad (22)$$

4) 设定限度值 η , 误差的均方差值 R 不低于设定的阈值, 表明海面弱目标可以接收到相关的数据信号。

经系统性训练得到的预测精度对应的人工优化 PSO-RBF 神经网络分析结果进行预判, 相应的预判结果误差值如图 6 所示。




图 6 IPIX 雷达数据的预测结果真实值与测试值

分析图 6 对应的数据采集样本, 可以采集到的数据在 1 800~2 200 范围内的预判误差值较大, 表明采集目标位于 1 800~2 200 范围中, 同 IPIX 雷达采集到的 # 18 海面杂散波形数据同首个距离单位内的实际情况相吻合。

借助人工优化 RBF 神经网络及标准的优化 PSO-RBF 分布进行预估, 得到的数据对比结果如表 2 所示。

表 2 3 种算法在实测数据中的性能比较

算法	RBF	标准 PSO-RBF	优化后的 PSO-RBF
RMSE 值	0.047	0.0143	0.002 34

仿真模拟实验表明, 对于尚无弱目标的海面杂散波形数据监测结果, 基于混沌特性, 可以借助人工优化 RBF 神经网络及 PSO-RBF 神经网络进行单一步长内的预估。对于弱目标下的海面杂散波形数据, 其存在破坏了原有的混沌特点, 导致相关的预估误差值大于单一的海面杂散波形数据值。

3 结 论

本文利用海杂波的混沌特性, 对其进行相空间重构, 同时在粒子群优化分析的基础上, 提出了一种改进的粒子群优化算法, 使粒子群算法陷入局部最小缺陷得到改善。将改进算法应用于 RBF 神经网络的隐层节点参数构造造成改进的 PSO-RBF 海杂波目标检测器, 对含有目标的数据单元数据对消误差和总误差均方根比较大, 纯海杂波背景下对消误差和总误差均方根接近于 0。使得海杂波背景下的弱目标检测效果比较好。经仿真和实际的海杂波数据证

明, 改进的 PSO-RBF 神经网络效果明显优于一般的 RBF 神经网络效果。

参考文献

- [1] ROY L P, KUMAR R V R. Accurate k-distributed clutter model for scanning radar application[J]. IET Radar, Sonar & Navigation, 2010, 21(3): 256-288.
- [2] HAYKIN S, XIAO B L. Detection of signals in chaos[J]. Proceedings of the IEEE, 1995, 8(1): 95-122.
- [3] LEUNG H, DUBASH N, XIE N. Detection of small objects in clutter using a GA-RBF neural network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2002, 38(1): 98-118.
- [4] 王福友. 海杂波混沌分形特性分析、建模及小目标检测[D]. 哈尔滨: 哈尔滨工程大学, 2009.
- [5] 行鸿彦, 金天力. 基于对偶约束最小二乘支持向量机的混沌海杂波背景中的微弱信号检测[J]. 物理学报, 2010, 59(1): 140-146.
- [6] 董华春, 宗成阁, 权太范. 高频雷达海洋回波信号的混沌特性研究[J]. 电子学报, 2000, 28(3): 25-28.
- [7] KENNEL M B, BROWN R, ABARBANEL H D J. Determining embedding dimension for phase-space reconstruction using a geometrical construction[J]. Physical Review A, 1992, 45(6): 3303-3411.
- [8] FRASER A M, SWINNEY H L. Independent coordinates for strange attractors from mutual information[J]. Physical Review A, 1986, 33(2): 1134-1140.
- [9] 刘国发, 王玉振. PSO-RBF 神经网络在导水裂缝带高度预测中的应用[J]. 中国矿业, 2018, 27(5): 128-131.
- [10] 夏爽, 李丽宏. 基于 PSO-RBF 神经网络在温室温度预测中的应用[J]. 计算机工程与设计, 2017, 38(3): 744-748.
- [11] 徐盼盼. 基于海杂波混沌特性的弱目标检测[D]. 大连: 大连海事大学, 2017.
- [12] 周文冬. 基于 PSO 的自组织 RBF 神经网络优化设计及应用研究[D]. 北京: 北京工业大学, 2016.
- [13] 侯倩. 基于海杂波空时混沌特性的小弱目标检测方法研究[D]. 重庆: 重庆大学, 2016.
- [14] TAKENS F. Forced oscillations and bifurcations[D]. Utrecht: Mathematical Institute of Utrecht University, 1974: 1-61.
- [15] 赵彦平, 张亚丽. 混沌时间预测方法的高分辨率雷达海杂波非线性分析[J]. 舰船科学技术, 2017, 39(8): 115-117.
- [16] 杨睿岑. 基于分形的海杂波目标检测研究[D]. 南京: 南京信息工程大学, 2017.

作者简介

石嘉, 硕士研究生, 主要研究方向为雷达目标检测。

E-mail: 13182169819@163.com

夏德平, 硕士、高级工程师, 主要研究方向为雷达系统总体技术。

E-mail: 2692063454@qq.com