基于稀疏度阶数优化的杂波密度估计算法

郭云飞†, 钱恒泽
(杭州电子科技大学 自动化学院，杭州 310018)

摘 要: 针对杂波分布不均匀且密度未知的多目标跟踪问题,提出一种基于稀疏度阶数优化的杂波密度估计算法. 首先,剔除在跟踪门内的潜在目标测量,获取杂波测量集;其次,从杂波测量集中构造“稀疏度阶数-超立方体容积”的样本,并利用支持向量回归机对样本拟合;再次,通过梯度法求得拟合曲线的极值点,实现稀疏度阶数在线优化;最后,将优化后的杂波稀疏度估计器嵌入高斯混合概率假设密度滤波器中,实现复杂杂波环境下目标状态与杂波密度联合估计. 仿真结果验证了所提出算法的有效性.

关键词: 杂波密度估计；多目标跟踪；稀疏度阶数优化；概率假设密度；支持向量回归机；梯度法
中图分类号: TN953 **文献标志码:** A
DOI: 10.13195/j.kzyjc.2019.0429 **开放科学(资源服务)标识码(OSID):**
引用格式: 郭云飞,钱恒泽. 基于稀疏度阶数优化的杂波密度估计算法[J]. 控制与决策, 2020, 35(12): 2923-2930.

A clutter density estimation algorithm by optimized sparsity order

GUO Yun-fei†, *QIAN Heng-ze*
(Automation School，Hangzhou Dianzi University，Hangzhou 310018，China)

Abstract: In order to address the problem of multi-target tracking by nonuniform clutter spatial distribution and unknown density, a clutter density estimator based on sparsity order optimization is proposed. Firstly, the clutter set is obtained by eliminating the potential target-originated measurements that fall within the validation gate. Then, the samples of “sparsity order-hypercube volume” are constructed from the clutter set and the corresponding fitting function is established by the support vector regression machine. Furthermore, the sparsity order is optimized online by finding the mininum using the gradient method. Finally, the clutter sparsity estimator is combined by the Gaussian mixture probability hypothesis density to estimate the clutter density and target state in complicated backgroud simultaneously. Simulation results show the effectiveness of the proposed algorithm.

Keywords: clutter density estimation；multi-target tracking；sparsity order optimization；probability hypothesis density；support vector regression machine；gradient

0 引 言

目标跟踪是信息融合领域的研究热点之一,在雷达、声呐探测、战场态势感知和空中交通管制等军事和民用领域具有重要的科学意义和应用价值[1]. 在实际跟踪环境中,目标的测量信息会受到各种杂波干扰,如电磁波、地海杂波、有源干扰和多径效应等. 传统算法通常假设杂波在观测空间均匀分布且杂波密度已知[2-3]. 该假设在复杂杂波环境下,如海岸线附近和复杂的地海杂波,会受到严峻挑战,此时,杂波空间分布不均匀且密度未知. 当假设的杂波模型与实际不匹配时会严重影响目标跟踪性能[2].

针对杂波分布未知的情况,文献[2]在初始杂波个数远大于目标个数的假设下,提出了基于有限混合模型的杂波模型,并利用期望最大化(expectation maximization, EM)算法对杂波参数进行估计. 文献[3]在非线性情况下,提出了基于拟蒙特卡罗的未知杂波滤波器,利用有限混合模型拟合位置杂波空间分布. 文献[4]提出了基于概率假设密度(probability hypothesis density, PHD)的交互式杂波密度估计算法,利用数据关联算法获取杂波测量概率,同时用杂波测量概率计算杂波生成器的协方差,但在非线性测量环境中存在估计偏差. 文献[5]提出了基于核密度估计的杂波密度未知时多目标跟踪算法,该算法利用核密度估计器来估计杂波空间分布的概率密

收稿日期: 2019-04-08；**修回日期:** 2019-09-07.
基金项目: 浙江省自然科学基金重点项目(LZ20F010002)；国家自然科学基金项目(61871166).
责任编委: 张维海.
†通讯作者. E-mail: gyf@hdu.edu.cn.

度函数. 文献 [2-5] 在状态空间估计杂波密度, 杂波估计器与状态估计器相互耦合. 文献 [6] 提出了在测量空间的杂波稀疏度估计器 (spatial clutter sparsity estimation, SCSE), 该杂波估计器与状态估计器相互独立. SCSE 通过计算待测量点到另一个测量点的超立方体容积来求取待测量点的杂波密度, 但固定的稀疏度阶数在杂波分布不均匀时影响杂波估计的性能. 文献 [7] 在文献 [6] 的基础上将单帧 SCSE 推广到多帧 SCSE, 减少了新生目标测量对杂波密度估计的影响.

针对杂波分布不均匀且密度未知问题, 本文提出一种基于稀疏度阶数优化的杂波密度估计器 (clutter density estimator by optimized sparsity order, CDEOSO). 该方法在杂波分布不均匀且密度未知时能对杂波稀疏度阶数在线优化: 一方面, 将状态信息反馈至杂波密度估计中, 以减小因目标测量带来的杂波密度估计偏差; 另一方面, 通过支持向量回归机稀疏度阶数在线估计的算法求解优化后的稀疏度阶数, 可以避免传统方法选取固定稀疏度阶数而导致杂波估计偏差, 实现在杂波分布不均匀且密度未知时对目标进行跟踪.

1 问题描述

假设传感器在探测范围内对 N_k 个目标进行监控 ($N_k \geqslant 0$ 且未知). 记第 t 个单目标在 k 时刻的状态为 $X_{k,t} = [x_{k,t}, y_{k,t}, \dot{x}_{k,t}, \dot{y}_{k,t}]^{\mathrm{T}}$ $(0 \leqslant t \leqslant N_k)$, 其中 $(x_{k,t}, y_{k,t})$ 和 $(\dot{x}_{k,t}, \dot{y}_{k,t})$ 分别为 k 时刻目标 t 的位置和速度. 目标的匀速直线运动模型为

$$X_{k,t} = F \cdot X_{k-1,t} + \varpi_{k-1,t}, \tag{1}$$

$$F = I_2 \otimes \begin{bmatrix} 1 & \tau \\ 0 & 1 \end{bmatrix}. \tag{2}$$

其中: F 为状态转移矩阵; I_2 为二阶单位矩阵; $\otimes$ 为 Kronecker 积; τ 为传感器的扫描周期; 过程噪声 $\varpi_{k-1,t} \sim N(0, Q)$, Q 为过程噪声协方差.

假设传感器在 k 时刻收到 M_k 个测量, 测量集记为 $Z_k = \{z_{k,i}\}_{i=1}^{M_k}$, 其中第 i $(1 \leqslant i \leqslant M_k)$ 个测量 $z_{k,i}$ 来自目标或者杂波. 记截止到 k 时刻的测量集为 $Z_{1:k} = \{Z_1, Z_2, \ldots, Z_k\}$, $z_{k,i}$ 定义如下:

$$z_{k,i} = \begin{cases} h(X_{k,t}) + w_{k,i}, \\ \varUpsilon_{k,i}. \end{cases} \tag{3}$$

其中: $h(X_{k,t})$ 对应于 k 时刻第 t 个目标的观测方程; 测量噪声 $w_{k,i}$ 服从正态分布, $w_{k,i} \sim N(0, R)$; $\varUpsilon_{k,i}$ 为分布未知的杂波. 由于杂波在测量空间中分布未知且未必均匀, 杂波密度将与测量空间的具体测量点有关. 记 z 为测量空间中的任意一点, k 时刻测量点 z 处的杂波密度为 $c_k(z)$, 则 k 时刻的杂波个数为

$$\lambda_{c,k} = \int_U c_k(z)\mathrm{d}z, \tag{4}$$

其中 U 为当前的测量空间. 要解决的问题是, 在杂波分布不均匀且密度未知下, 利用传感器收到的测量集合 $Z_{1:k}$ 估计目标个数 N_k、目标状态 $\{X_{k,t}\}_{t=1}^{N_k}$ 和杂波密度 $\hat{c}_k(z)$.

2 基于稀疏度阶数优化的杂波密度估计算法

2.1 稀疏度阶数固定的杂波密度估计

传统的 SCSE 通过计算待测量点到另一个测量点的超立方体的容积来求取待测量点的杂波密度. 当杂波分布均匀时, 稀疏度阶数 n 越大, 杂波估计的方差越小[6]; 当杂波分布不均匀时, 通常稀疏度阶数 n 取固定值, 这会导致杂波估计效果变差.

记 n 为 SCSE 选定的稀疏度阶数, $r_k^{(n)}(z)$ 为待测量点到第 n 个测量点近邻距离, $V(r_k^{(n)}(z))$ 在三维空间内为超立方体的容积, 在二维空间内为矩形的面积, 则第 k 时刻测量点 z 处杂波的稀疏度为 $\hat{\gamma}_k(z)$[6], 其倒数第 k 时刻测量点 z 处的杂波密度为 $\hat{c}_k(z)$, 即

$$\hat{\gamma}_k(z) = \frac{V(r_k^{(n)}(z))}{n}, \tag{5}$$

$$\hat{c}_k(z) = \frac{1}{\hat{\gamma}_k(z)}. \tag{6}$$

传统的 SCSE 是面向测量的算法, 与滤波器独立且易嵌入滤波器中, 但在杂波分布不均匀时, 稀疏度阶数选取固定值会使杂波密度估计效果变差. 图 1 为杂波分布不均匀的情况, 其中 $z_{k,i}^{(n_1)}$、$z_{k,i}^{(n_2)}$、$z_{k,i}^{(n_3)}$、$z_{k,i}^{(n_4)}$、$z_{k,i}^{(n_5)}$ 和 $z_{k,i}^{(n_6)}$ 为待测量点 $z_{k,i}$ 的邻近测量. 传统的 SCSE 算法在计算 $z_{k,i}$ 处的杂波稀疏度时通常令 $n_1 = n_2 = n_3 = n_4 = n_5 = n_6 = n$, n 的值通常为 $n = 1$ 或 $n = 2$, 但这会造成一定的杂波密度估计偏差[6].

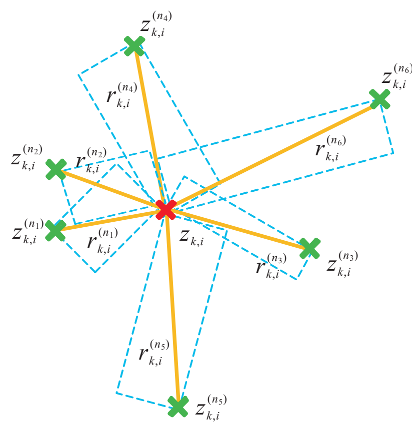

图 1 SCSE 示意图

图1中虚线框区域面积为二维空间矩形的面积 $V(r_k^{(n)}(z))$, $z_{k,i}^{(n_j)}$ 为距离k时刻的任意测量点 $z_{k,i}$ 第j近的杂波测量,用 $r_{k,i}^{(n_j)}$ 表示第j近距离,n为稀疏度阶数,n_1、n_2、n_3、n_4、n_5和n_6分别为 $z_{k,i}^{(n_1)}$、$z_{k,i}^{(n_2)}$、$z_{k,i}^{(n_3)}$、$z_{k,i}^{(n_4)}$、$z_{k,i}^{(n_5)}$ 和 $z_{k,i}^{(n_6)}$ 所对应的杂波稀疏度阶数.

2.2 CDEOSO算法

针对固定的稀疏度阶数影响杂波密度估计性能的问题,本节提出基于支持向量回归机稀疏度阶数在线估计的算法,并将利用优化的稀疏度阶数产生的杂波密度估计器与高斯混合概率假设密度滤波器[8-9]相结合来联合估计多目标状态和杂波密度. 算法的流程如图2所示.

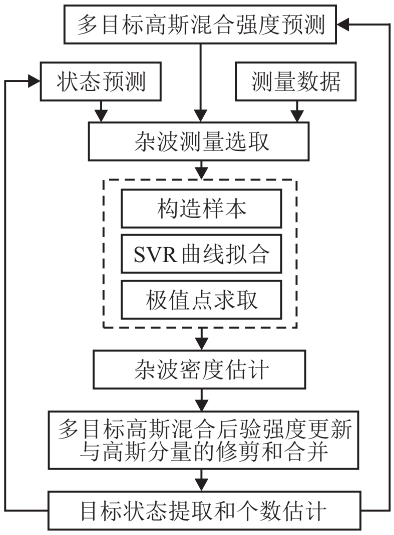

图2 CDEOSO算法流程

首先,利用高斯混合后验强度信息反馈和门限技术剔除潜在的目标测量,获取杂波测量集,减小目标测量对杂波密度估计的影响;其次,从杂波测量集中构造“稀疏度阶数-超立方体容积”的样本并利用基于支持向量回归机(support vector regression machine, SVR)对样本拟合;再次,求出拟合曲线的极值点并实现稀疏度阶数的在线优化,避免非均匀杂波下固定的稀疏度带来杂波密度估计偏差;将优化后的稀疏度阶数应用于杂波稀疏度估计,可求得杂波密度;最后,将杂波密度估计的结果代入多目标高斯混合强度更新中,实现在杂波分布不均匀且密度未知时对目标进行跟踪.

step 1: 多目标强度预测.

假设$k-1$时刻多目标的后验强度的高斯混合PHD为

$$v_{k-1}(x)=\sum_{i=1}^{J_{k-1}}\omega_{k-1}^{(i)}N(x;m_{k-1}^{(i)},P_{k-1}^{(i)}). \tag{7}$$

其中: J_{k-1}为$k-1$时刻的高斯分量个数,x为目标状态空间中的值,$\omega_{k-1}^{(i)}$、$m_{k-1}^{(i)}$和$P_{k-1}^{(i)}$分别为$k-1$时刻第i个高斯分量的权重、均值和方差.

由$k-1$时刻幸存至k时刻的目标的PHD为

$$v_{k|k-1,S}(x)=P_S\sum_{i=1}^{J_{k-1}}\omega_{k-1}^{(i)}N(x;m_{k|k-1}^{(i)},P_{k|k-1}^{(i)}), \tag{8}$$

$$m_{k|k-1}^{(i)}=Fm_{k-1}^{(i)}, \tag{9}$$

$$P_{k|k-1}^{(i)}=Q+FP_{k-1}^{(i)}F^{\mathrm{T}}. \tag{10}$$

其中: P_S为高斯分量幸存概率,$m_{k|k-1}^{(i)}$和$P_{k|k-1}^{(i)}$分别为k时刻第i个高斯幸存分量的均值和协方差.

k时刻新生分量为

$$B_k(x)=\sum_{i=1}^{J_{B,k}}\omega_{B,k}^{(i)}N(x;m_{B,k}^{(i)},P_{B,k}^{(i)}). \tag{11}$$

其中: $\omega_{B,k}^{(i)}$、$m_{B,k}^{(i)}$和$P_{B,k}^{(i)}$分别为k时刻第i个新生分量的权重、均值和协方差,$J_{B,k}$为k时刻新生高斯分量的个数.

k时刻预测强度的高斯混合为k时刻幸存的高斯分量$v_{k|k-1}(x)$与k时刻的新生分量$B_k(x)$之和,即

$$v_{k|k-1}(x)=v_{k|k-1,S}(x)+B_k(x). \tag{12}$$

step 2: 杂波测量的选取.

对$k-1$时刻的第i个高斯分量$m_{k-1}^{(i)}$进行预测,第i个预测高斯分量$m_{k|k-1}^{(i)}$跟踪门计算[10]如下:

$$J_{z_{k,j}}^{(i)}=\tilde{z}_k^{(i)\mathrm{T}}[S_k^{(i)}]^{-1}\tilde{z}_k^{(i)}\leqslant g^2, \tag{13}$$

$$\tilde{z}_k^{(i)}=z_{k,j}-h_k(m_{k|k-1}^{(i)}), \tag{14}$$

其中g为跟踪门参数.

从k时刻的测量集Z_k中选取落入跟踪门内的近邻测量$\hat{Z}_k^t$,记$\hat{Z}_k^t$为潜在目标测量;再从k时刻的测量集Z_k中剔除$\hat{Z}_k^t$得到当前杂波集Z_k^C, $Z_k^C=Z_k\backslash\hat{Z}_k^t$.

step 3: 构造“$n-V$”样本.

如图1所示,以k时刻任意测量点$z_{k,i}$作为待测量点,以k时刻距离待测量点第n近邻矩形面积作为样本点的纵坐标,样本点的横坐标为稀疏度阶数n,可将k时刻的样本点表示为$(n,V(r_k^{(n)}(z)))$. 定义数集$\boldsymbol{N}\triangleq\{1,2,\ldots,n,\ldots,n_{\max,k}\}$, $n\in\boldsymbol{N}$, k时刻的样本集$\boldsymbol{C}=\{(n,V(r_k^n(z)))\}_{n=1}^{n_{\max,k}}$. 其中: $n_{\max,k}=|Z_k^C|$为k时刻观测空间内的杂波测量个数,z是维数为l的测量点.

step 4: SVR曲线拟合.

当杂波分布不均匀时对杂波密度进行估计,其中杂波分布不均的情况如图3所示. 在圆形区域O_1内杂波分布均匀,在圆形区域O_2内杂波分布不均匀,求取待测量点$z_{k,i}$处的杂波密度.

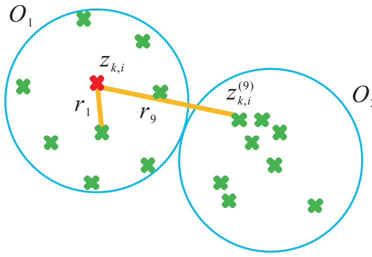

图3 杂波分布情况

定义k时刻的样本点$(n, V(r_k^{(n)}(z)))$处的比率$\varPsi_k(n)$为

$$\varPsi_k(n) = \frac{V(r_k^{(n)}(z))}{n}. \tag{15}$$

SCSE假设杂波分布均匀[6],杂波稀疏度近似为一个常数,比率$\varPsi_k(n)$也近似为常数;当杂波分布不均匀时,杂波稀疏度和比率$\varPsi_k(n)$也不再是常数. 如图3所示,当杂波分布均匀时,k时刻任意测量点$z_{k,i}$的杂波稀疏度估计随着杂波稀疏度阶数n的增大而更加精确,直至$z_{k,i}^{(9)}$处杂波分布不再均匀. 在此情况下,通过CDEOSO算法求取优化后的杂波稀疏度阶数为9. 本文利用SVR对样本集$\boldsymbol{C}$进行拟合,通过对拟合曲线求解极值点来求取优化后的杂波稀疏度阶数. 图3中:$z_{k,i}^{(9)}$为距离$z_{k,i}$第9近的杂波测量,r_9为距离$z_{k,i}$第9近的距离长度.

首先通过SVR对样本集$\boldsymbol{C}$进行拟合,最大化目标函数$W(\alpha;\vartheta)$来求解拉格朗日系数α;然后,通过使推广误差Er最小来获取参数θ,从而确定决策函数$f(x;\alpha,\sigma)$.

定义拉格朗日系数为$\{\alpha_i\}_{i=1}^{n_{\max,k}}$和$\{\alpha_i^*\}_{i=1}^{n_{\max,k}}$, $\alpha_i \in [0, M]$, $\alpha_i^* \in [0, M]$, M为惩罚因子. 令$\alpha = [\alpha_1, \ldots, \alpha_{n_{\max,k}}, \ldots, \alpha_1^*, \ldots, \alpha_{n_{\max,k}}^*]^{\mathrm{T}}$. 其中: 目标函数$W(\alpha;\vartheta)$的所有参数统一表示为$\vartheta = \{M, \varepsilon, \sigma\}$, σ为高斯核函数的带宽. 为了使模型具备一定的推广性,采用δ折交叉验证,将样本集$\boldsymbol{C}$划分为δ个子集,其中$\delta-1$个子集作为训练集,剩下的子集作为测试集. 定义推广误差Er如下:

$$\mathrm{Er} = \frac{1}{\delta}\sum_{j=1}^{\delta}\sqrt{\frac{\delta}{n_{\max,k}}\sum_{n=l(j)}^{j\cdot n_{\max,k}/\delta}(V(r^{(n)}(z)) - f(n))^2}. \tag{16}$$

其中: $l(j) = 1 + (j-1)\cdot(n_{\max,k}/\delta)$; δ为经验参数,通常$\delta = 5$[11].

SVR算法步骤为: 首先,令参数$\theta = [M, \varepsilon, \sigma]$,使用遗传算法[11]寻求使Er最小的参数$\theta$,记为最优参数$\hat{\theta}$;然后,在确定最优参数$\hat{\theta}$后使用二次规划寻找使得$W(\alpha;\vartheta)$目标函数最大化的系数$\alpha$,即

$$\hat{\alpha} = \arg\max_{\alpha} W(\alpha;\vartheta); \tag{17}$$

最后,将所获得的参数$\hat{\theta}$和拉格朗日系数$\hat{\alpha}$代入决策函数$f(x;\hat{\alpha},\hat{\sigma})$中,获取所需的拟合函数.

step 5: 极值点的求取.

利用梯度法求取上述step 4拟合曲线的极值点,极值点的横坐标向下取整即为优化后的稀疏度阶数n,将求取的稀疏度阶数n代入式(5)和(6),得到基于稀疏度阶数优化的杂波密度估计$\hat{c}_k(z)$. 极小值点的迭代横坐标和极大值点的迭代横坐标如下:

$$x_{\min,s} = x_{\min,s-1} - \beta\cdot\frac{\partial f(x;\hat{\alpha},\hat{\sigma})}{\partial x}, \tag{18}$$

$$x_{\max,s} = x_{\max,s-1} + m\cdot\frac{\partial f(x;\hat{\alpha},\hat{\sigma})}{\partial x}. \tag{19}$$

其中: s为迭代次数, $s=0$时,初始值$x_{\min,s=0} = 1$, $x_{\max,s=0} = 1$, $x_{\min,s}$为s次迭代后的极小点的横坐标, $x_{\max,s}$为s次迭代后的极大点的横坐标; β为梯度步长; m为学习速率. 求取极小点和极大点的横坐标中的较小值并向下取整即为最优杂波稀疏度的近邻阶数n,即

$$\hat{n}(z) = \min\{\lfloor x_{\max,s}\rfloor, \lfloor x_{\min,s}\rfloor\}, \tag{20}$$

其中$\lfloor\cdot\rfloor$为向下取整. 将求取的稀疏度阶数$\hat{n}(z)$代入式(5)和(6),得到基于稀疏度阶数优化的杂波密度估计$\hat{c}_k(z)$.

step 6: 多目标强度更新与高斯分量的修剪和合并.

利用估计的第k帧杂波密度$\hat{c}_k(z)$,结合高斯混合概率,假设密度滤波器对预测强度函数中的高斯分量进行更新,得到多目标后验强度为

$$v_k(x) = (1 - P_d)v_{k|k-1}(x) + \sum_{z\in Z_k}\frac{P_d g_k(z|x)v_{k|k-1}(x)}{c_k(z) + \int P_d g_k(z|\xi)v_{k|k-1}(\xi)\mathrm{d}\xi}. \tag{21}$$

其中: P_d为检测概率, $v_{k|k-1}(x)$为预测强度, $g_k(\cdot)$为似然函数, $c_k(z)$为杂波密度.

由于高斯分量的持续增多会增加计算的复杂度,对后验强度函数公式(21)中的高斯分量$m_k^{(i)}$进行修剪. 修剪后保留的高斯分量为权重大于阈值T_p的分量,即

$$\omega_k^{(i)} > T_p,\ i = 1, 2, \ldots, J_k. \tag{22}$$

邻近高斯分量$m_k^{(i)}$和$m_k^{(j)}$满足$(m_k^{(i)} - m_k^{(j)})^{\mathrm{T}}\times(P_k^{(i)})^{(-1)}(m_k^{(i)} - m_k^{(j)}) \leqslant T_m$,进行合并操作. 其中: T_p为高斯权重修剪阈值, T_m为合并阈值. 从而得到k时刻后验强度的高斯混合$\{\omega_k^{(i)}, m_k^{(i)}, P_k^{(i)}\}_{i=1}^{J_k}$.

step 7: 多目标状态提取和个数估计.

利用step 6获取的k时刻后验强度的高斯混合$\{\omega_k^{(i)}, m_k^{(i)}, P_k^{(i)}\}_{i=1}^{J_k}$进行多目标状态提取. 目标个数估计为

$$\hat{N}_k = \mathrm{round}\Big(\sum_{i=1}^{J_k} \omega_k^{(i)}\Big), \tag{23}$$

其中round(·)为四舍五入取整. 目标状态估计为前$\hat{N}_k$个权重最大的高斯分量所对应的均值.

由上述步骤可知,利用跟踪门技术和目标反馈可有效获取杂波测量,通过SVR对样本的拟合能对杂波稀疏度阶数在线优化,避免选取固定值带来杂波估计的偏差,提升杂波稀疏度估计的精度,并将杂波估计结果嵌入至高斯混合概率密度的更新步中,提升多目标跟踪的性能.

3　仿真分析

仿真以无源协同定位为应用背景,利用本文所提出算法实现杂波分布不均匀且密度未知时的多目标跟踪. 通过与已知杂波下的GM-PHD算法、EM算法[2]、SCSE-GMPHD[6]和MCSE-GMPHD[7]的比较,验证本文算法的有效性.

3.1　参数设置

探测区域为$[-800, 800] \times [-1\,300, 600]\,\mathrm{m}^2$,场景内共有3个目标,每个目标做近似匀速直线运动,目标初始状态如表1所示.

表1　目标场景设置

目标编号	初始位置/m	初始速度/(m/s)
1	(−600, −400)	(17, 17)
2	(−400, 600)	(26, −26)
3	(80, 120)	(17, 8)

表1中: 目标1在第1 s产生,到第60 s消失; 目标2在第21 s产生,到第50 s消失; 目标3在第39 s产生,到第60 s消失. 接收站位置记为$X_R = [x_R, y_R]^{\mathrm{T}}$,第$k$时刻的外发射站位置记为$X_{k,T} = [x_{k,T}, y_{k,T}]^{\mathrm{T}}$. k时刻的非线性测量方程为

$$h_k(X_{k,t}, X_R, X_{k,T}) = \begin{bmatrix} r_k \\ \theta_k \end{bmatrix}, \tag{24}$$

$$r_k = \|X_{k,t} - X_{k,T}\| + \|X_R - X_{k,t}\| - \|X_R - X_{k,T}\|, \tag{25}$$

$$\theta_k = \arctan\Big(\frac{y_{k,t} - y_R}{x_{k,t} - x_R}\Big). \tag{26}$$

其中: r_k表示第k时刻的距离差, θ_k表示第k时刻回波路径相对于直达波路径的方位角.

采样间隔$\tau = 1\,\mathrm{s}$,过程噪声的标准差$\sigma_v = 0.1\mathrm{m/s}^2$. 传感器测量噪声在距离和角度上的标准差分别为$\sigma_r = 6\,\mathrm{m}, \sigma_\theta = \pi/180\,\mathrm{rad}$. 正确测量落入跟踪门内的概率$P_G = 0.99$,跟踪门参数$g = 0.92$,检测概率$P_d = 0.95$,目标生存概率$P_s = 0.98$,高斯权重修剪阈值$T_p = 10^{-4}$,合并阈值$T_m = 4$,高斯分量最大个数$J_m = 100$. 新生目标强度函数为$\gamma_k(x) = \sum_{i=1}^{3} 0.1N(x; m_\gamma^{(i)}; P_\gamma)$,具体新生分量参数如表2所示. 蒙特卡罗仿真次数为100,每次仿真时间为60 s. 计算机参数如下: Intel(R) Core (TM) i7-8550U CPU @ 1.80 GHz,内存8.00 GB, 64位操作系统; 仿真软件为Matlab 2016.

表2　新生分量参数设置

分量编号	权重	均值/m	方差/m^2
1	0.1	$[-600, 0, -400, 0]^{\mathrm{T}}$	diag(100, 225)
2	0.1	$[-400, 0, 600, 0]^{\mathrm{T}}$	diag(100, 225)
3	0.1	$[80, 0, 120, 0]^{\mathrm{T}}$	diag(100, 225)

杂波个数N_c服从参数$\lambda_{c,k}$的泊松分布,其中$\lambda_{c,1\text{-}10} = 15, \lambda_{c,11\text{-}30} = 20, \lambda_{c,31\text{-}50} = 15, \lambda_{c,51\text{-}60} = 20$. 杂波空间分布$\kappa_k(z)$符合以下模型:

$$\kappa_k(z) = w_c^1 U(\cdot) + \sum_{i=2}^{3} w_c^i N(\cdot; m_c^i, P_c^i). \tag{27}$$

其中: 权重分别为$w_c^1 = 0.3, w_c^2 = 0.5, w_c^3 = 0.2$; $U(\cdot) = 1/V, V = \pi \times 2\,500\,\mathrm{rad}\cdot\mathrm{m}$; 各均值分别为$m_c^2 = [-\pi/3\,\mathrm{rad}, 1\,600\,\mathrm{m}], m_c^3 = [\pi/2\,\mathrm{rad}, 200\,\mathrm{m}]$, $P_c^2 = \mathrm{diag}(0.01\,\mathrm{rad}^2, 200\,\mathrm{m}^2), P_c^3 = \mathrm{diag}(0.2\,\mathrm{rad}^2, 300\,\mathrm{m}^2)$.

CDEOSO中的惩罚因子$M \in [0.001, \max(\|Y_m + 3\cdot \mathrm{Y}_s\|, \|Y_m - 3\cdot Y_s\|)], \varepsilon \in [0.000\,1, 5], \sigma \in [0.1\cdot\|n_{\max,k} - 1\|, 1\cdot\|n_{\max,k} - 1\|]$. 其中: Y_m为样本集的均值, Y_s为样本集的标准差. EM算法的初始分量个数为50,收敛阈值为10^{-5}. MCSE算法的积累帧数为15.

3.2　算法性能分析

为了验证本文所提出算法的有效性,使用3个指标: 估计的多目标个数、最优子分配距离评价准则(OSPA)[12]和算法耗时. OSPA定义为

$$\bar{d}_p^{(c)}(X, Y) = \Big(\frac{1}{l}\Big(\min_{\pi\in\Lambda_n} \sum_{i=1}^{m} d^{(c)}(x_i, y_{\pi(i)})^p + c^p(l-m)\Big)\Big)^{\frac{1}{p}}. \tag{28}$$

其中: X和Y为任意有限子集,维数分别为m和l; $d^{(c)}(x, y) = \min(c, d(x, y))$; $c > 0, 1 \leqslant p \leqslant \infty, \varPi_k$为$\{1, 2, \dots, k\}$的所有排列组合组成的集合. 本文仿真设置$c = 100\,\mathrm{m}, p = 2$.

杂波密度估计步骤复杂度为$O((\lambda_{c,k}M_k)(\lambda_{c,k}^2+N_{\rm Iter}))$, PHD滤波步骤复杂度为$O(J_{k-1}M_k)$. 其中: $(\lambda_{c,k}^2+N_{\rm Iter})$前半部分$\lambda_{c,k}^2$代表SVR的算法复杂度. $N_{\rm Iter}$为常数项,代表梯度法的复杂度. 算法复杂度可表示为

$$\mho=\begin{cases}O((\lambda_{c,k}M_k)\lambda_{c,k}^2),\ J_{k-1}<\lambda_{c,k}^3;\\ O(J_{k-1}M_k),\ J_{k-1}>\lambda_{c,k}^3.\end{cases}\tag{29}$$

图4为单次仿真的效果图,图5为单次仿真的测量结果. 从图4中可以看出,在非均匀杂波下能对目标进行跟踪.

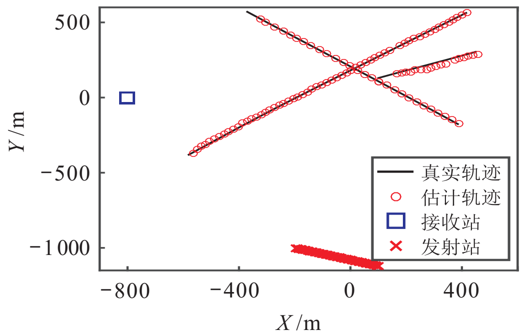

图4 单次仿真效果图

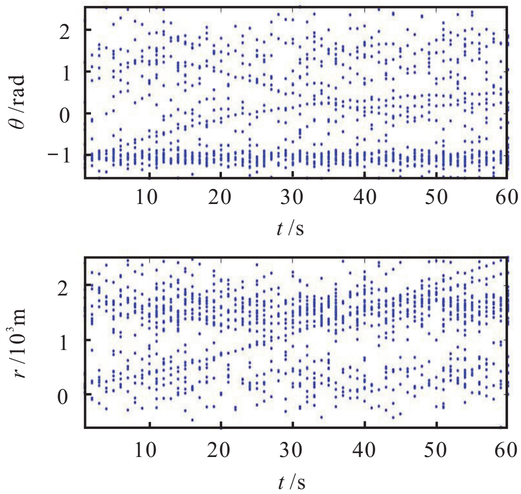

图5 单次仿真测量结果

图6给出了5个算法的目标个数估计的效果图. 可以看出: SCSE算法对目标个数的估计随时间出现明显的起伏,因为新生目标出现在杂波测量中,导致杂波密度偏大; EM算法由于初始分量个数较少,在初始时刻对目标个数估计较差,但随着分量个数的累积对目标估计效果逐渐变好; MCSE对目标个数的估计效果比CDEOSO差,这是因为MCSE 错误地选取了杂波稀疏度阶数,导致杂波密度估计出现偏差; 而CDESOS算法能够在非均匀的杂波环境对杂波稀疏度阶数在线优化. 不同算法的杂波密度估计如图7所示.

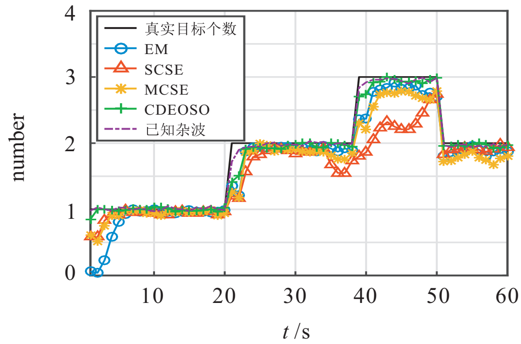

图6 目标个数估计效果图

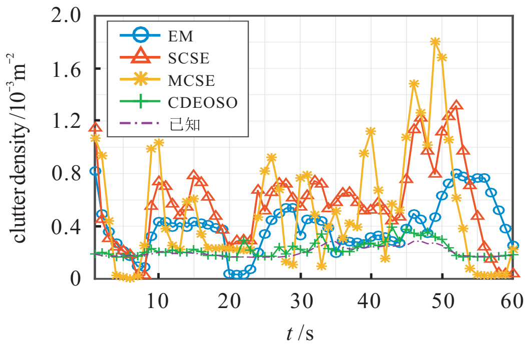

图7 杂波密度估计效果图

图8、图9、图10分别为$k=1$、$k=21$、$k=40$的高斯混合概率密度结果;高斯混合的权重、均值和协方差的3步过程见表3. 可知目标1的权值分别在$k=1$、$k=21$、$k=40$时为0.989、0.625、0.268,这是因为在$k=21$和$k=40$时出现了新生目标2和目标3,导致目标1的权重下降. 并且随着时间的增长,目标1的协方差矩阵不断变小,这是因为杂波密度的准确估计提升了目标跟踪的性能.

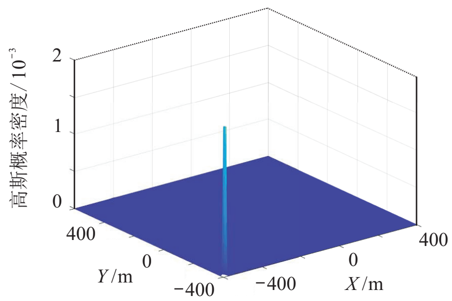

图8 $k=1$时刻的高斯混合概率密度

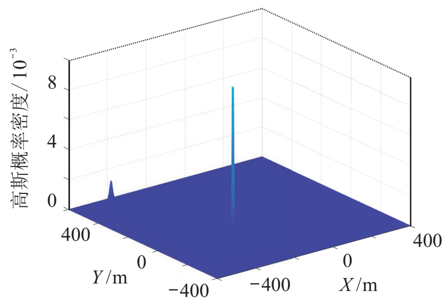

图9 $k=21$时刻的高斯混合概率密度

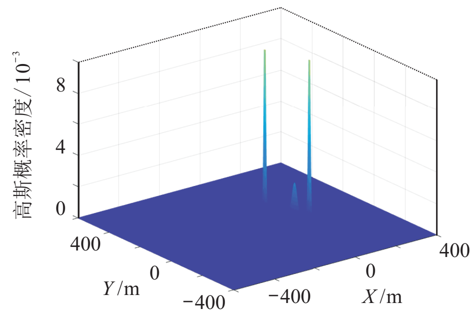

图 10　$k=40$时刻的高斯混合概率密度

表 3　高斯混合的权重、均值和协方差

k	w	m	P
1	0.989	$\begin{bmatrix}-598.2\\16.9\\-398.9\\16.9\end{bmatrix}$	$\begin{bmatrix}12.5 & 0 & 10.1 & 0\\0 & 400 & 0 & 0\\10 & 0 & 55.2 & 0\\0 & 0 & 0 & 400\end{bmatrix}$
21	0.625	$\begin{bmatrix}-249.7\\16.9\\-46.5\\16.8\end{bmatrix}$	$\begin{bmatrix}3 & 0.34 & -4.07 & -0.27\\0.34 & 0.08 & -0.33 & -0.03\\-4.07 & -0.33 & 15.94 & 1.26\\-0.27 & -0.03 & 1.26 & 0.18\end{bmatrix}$
40	0.268	$\begin{bmatrix}58.9\\16.1\\268.9\\16.5\end{bmatrix}$	$\begin{bmatrix}2.58 & 0.59 & -3.09 & -0.52\\0.59 & 0.09 & -0.59 & -0.04\\-2.09 & -0.59 & 10.19 & 1.21\\-0.52 & -0.04 & 1.21 & 0.15\end{bmatrix}$

图 11 是对样本进行 SVR 拟合的效果, 利用第 2.2 节的 step 5 可求出优化后的稀疏度阶数为 5, 部分样本点数据见表 4.

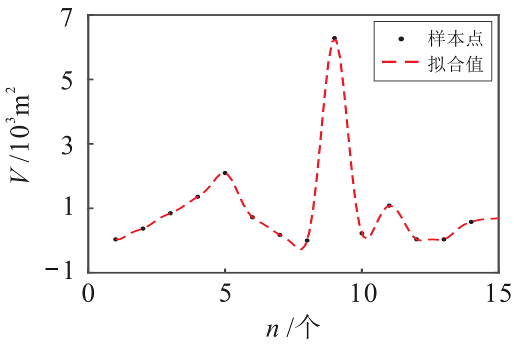

图 11　SVR 拟合效果图

表 4　部分样本数据

稀疏度阶数 n	1	2	3	4	5	6	7	8
V/m^2	16.2	367.1	839.3	1 342.2	2 101.4	764.2	138.1	12.4
稀疏度阶数 n	9	10	11	12	13	14	15	
V/m^2	6 283.1	128.5	1 085.2	25.3	42.1	580.9	692.5	

图 12 给出了 5 种算法下的 OSPA. EM 算法的起始 OSPA 在 5 种算法中最大, 由于在初始时刻初始分量个数较少, 导致偏差较大. 在第 36 时刻, 目标 1 和目标 2 处于交叉状态, 此时的 SCSE 算法会出现小峰值, 这是因为临近目标的出现将增加目标测量的密集度, 导致杂波密度偏大. 由于新生目标的出现有明显的峰值, 可以看出, CDEOSO 算法峰值下降的速度比 EM 算法、SCSE 算法和 MCSE 算法都快. 在峰值过后 OSPA 趋于平稳, 从表 5 可以看出, CDEOSO 算法在 OSPA 性能上优于 SCSE 算法、MCSE 算法和 EM 算法. 由于在对样本进行拟合的过程中会耗费一定时间, CDEOSO 算法耗时略高于 MCSE 算法.

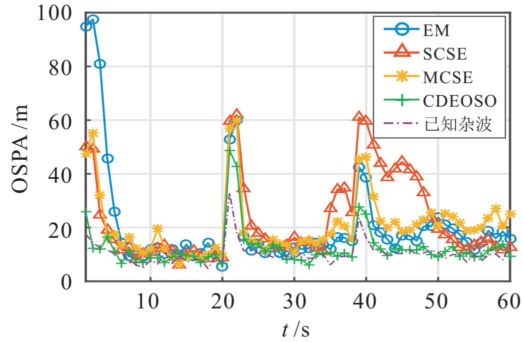

图 12　OSPA 效果图

表 5　单次平均耗时和 OSPA

性能指标	算法				
	SCSE	MSCE	EM	CDEOSO	已知杂波
耗时/s	1.982 6	2.389 3	53.892 4	3.324 2	0.578 9
OSPA/m	19.351	23.078	21.092	12.416	11.466

图 13 给出了各个算法相比较于已知杂波下的杂波个数 RMSE 效果图, 可以看出: SCSE 对杂波个数估计的效果最差; MSCE 由于考虑多帧杂波, 其对杂波个数的估计效果比 SCSE 要好; 由于 EM 算法初始分量个数较少, 在初始时刻的杂波个数估计最差, 但随着分量个数的累积, EM 算法估计效果比 SCSE 和 MCSE 要好; CDEOSO 算法是 4 种算法中对杂波个数估计偏差最小的, 平均值低于 0.2, 计算数值见表 6, 这是因为 CDEOSO 算法在杂波不均匀且未知情况下能对杂波稀疏度阶数进行在线优化.

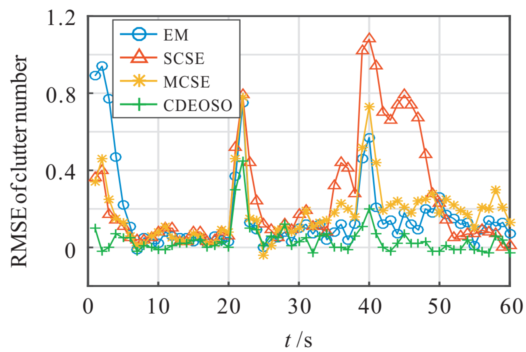

图 13　杂波个数 RMSE 效果图

表6 杂波个数平均RMSE

算法	SCSE	MSCE	EM	CDEOSO
平均RMSE/s	0.2438	0.1672	0.1507	0.0233

由上述仿真结果可知,本文算法(CDEOSO)有效提升了多目标跟踪的性能.

4 结 论

针对固定的稀疏度阶数影响杂波密度估计性能的问题,本文提出了基于稀疏度阶数优化的杂波密度估计算法. 在杂波分布不均匀时,能对稀疏度阶数进行在线优化,避免了选取固定值会降低杂波估计的情况,有效提升了杂波分布不均匀且密度未知时多目标跟踪的性能. 在实际工程中杂波分布情况复杂,例如多径杂波和地海杂波[13],对此,本文算法未能达到理想的效果. 下一步工作是与相关部门进行合作,在实际工程中进一步完善本文算法.

参考文献(References)

[1] 彭华甫, 黄高明, 田威. 随机有限集理论及其在多目标跟踪中的应用和实现[J]. 控制与决策, 2019, 34(2): 225-232.
(Peng H F, Huang G M，Tian W. Random finite set: Theory, application and implementation for multi-target tracking[J]. Control and Decision, 2019, 34(2): 225-232.)

[2] Lian F, Han C Z, Liu W F. Estimating unknown clutter intensity for PHD filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2010, 46(4): 2066-2078.

[3] 李翠芸, 江舟, 姬红兵, 等. 基于拟蒙特卡罗的未知杂波GMP-PHD滤波器[J]. 控制与决策, 2014, 29(11): 1997-2001.
(Li C Y, Jiang Z, Ji H B, et al. GMP-PHD filter based on quasi-MonteCarlo in unknown clutter[J]. Control and Decision, 2014, 29(11): 1997-2001.)

[4] Kim W C, Song T L. Interactive clutter measurement density estimator for multitarget data association[J]. IET Radar Sonar and Navigation, 2017, 11(1): 125-132.

[5] Chen X, Tharmarasa R, Kirubarajan T, et al. Online clutter estimation using a Gaussian kernel density estimator for multitarget tracking[J]. IET Radar Sonar and Navigation, 2015, 9(1): 1-9.

[6] Song T L, Musicki D. Adaptive clutter measurement density estimation for improved target tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2011, 47(2): 1457-1466.

[7] 郭云飞, 潘金星, 才智. 基于多帧杂波稀疏度估计的无源协同定位[J]. 控制理论与应用, 2018, 35(7): 981-987.
(Guo Y F, Pan J X, Cai Z. GMPHD based multi-scan clutter sparsity estimation[J]. Control Theory & Application, 2018, 35(7): 981-987.)

[8] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4091-4104.

[9] Mahler R P S. Multitarget Bayes filtering via first-order multitarget moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.

[10] Dehkordi M Y, Azimifar Z. Novel N-scan GM-PHD-based approach for multi-target tracking[J]. IET Signal Processing, 2016, 10(5): 493-503.

[11] Liu S Y, Tai H J, Ding Q S, et al. A hybrid approach of support vector regression with genetic algorithm optimization for aquaculture water quality prediction[J]. Mathematical and Computer Modelling, 2013, 58(3): 458-465.

[12] Schuhmacher D, Vo B T, Vo B N. A consistent metric for performance evaluation of multi-object filters[J]. IEEE Transactions on Signal Processing, 2008, 56(8): 3447-3457.

[13] 万显荣, 赵志欣, 柯亨玉, 等. 基于DRM数字调幅广播的高频外辐射源雷达实验研究[J]. 雷达学报, 2012, 1(1): 11-18.
(Wan X R, Zhao Z X, Ke H Y, et al. Experimental research of HF passive rader based on DRM digital AM broadcasting[J]. Journal of Radars, 2012, 1(1): 11-18.)

作者简介

郭云飞(1978−), 男, 教授, 博士生导师, 从事信息融合、目标跟踪、非线性滤波、弱目标检测等研究, E-mail: gyf@hdu.edu.cn;

钱恒泽(1994−), 男, 硕士, 从事杂波密度估计的研究, E-mail: 928016037@qq.com.

(责任编辑：李君玲)