

基于泊松多伯努利混合滤波器的新生目标跟踪

鑑美玉 柳晓鸣

(大连海事大学信息科学技术学院 辽宁 大连 116026)

摘要 针对概率假设密度滤波器对新生目标的跟踪需要假设新生目标先验已知,其先验假设不合理,提出一种基于泊松多伯努利混合滤波器的新生目标跟踪方法。该方法根据泊松多伯努利混合滤波器共轭先验性质,获得当前量测为泊松过程和多伯努利混合过程的线性组成,并且将量测分别建立成新生目标量测和存活目标量测。以广义最优模式分配函数作为算法检测标准,实验结果表明,该方法对新生目标数目和目标位置的估计准确性均有较大提高。

关键词 多目标跟踪 随机有限集 泊松多伯努利混合 新生目标

中图分类号 TP391

文献标志码 A

DOI:10.3969/j.issn.1000-386x.2022.12.044

BIRTH TARGET TRACKING BASED ON POISSON MULTI-BERNOULLI MIXTURE FILTER

Jian Meiyu Liu Xiaoming

(College of Information Science and Technology, Dalian Maritime University, Dalian 116026, Liaoning, China)

Abstract Aimed at the problem of probability hypothesis density filter, which needs to assume that the new birth target is known a priori and its prior assumption is unreasonable, a new birth target tracking method based on Poisson multi-Bernoulli mixture filter is proposed. According to the conjugate prior property of Poisson multi-Bernoulli mixture filter, the method obtained the linear composition of the current measurement as Poisson process and multi-Bernoulli mixture process, and established the measurement as new birth target measurement and survival target measurement respectively. The generalized optimal subpattern assignment function was used as the algorithm detection standard. Experimental results show that the method greatly improves the estimation accuracy of the number of new birth targets and the target position.

Keywords Multi-target tracking Random finite sets Poisson multi-Bernoulli mixture Birth target

0 引言

多目标跟踪(Multiple Target Tracking, MTT)包括处理从多个目标获得的量测集以及估计目标的当前状态^[1-3]。解决 MTT 的难点在于目标和量测之间未知的对应关系。已有的 MTT 方法有联合概率数据关联(Joint Probabilistic Data Association, JPDA)滤波器、多假设跟踪器(Multiple Hypothesis Tracker, MHT)和基于随机有限集(Random Finite Sets, RFS)的算法^[4]。Mahler 基于 RFS 理论提出了概率假设密度(Probability Hypothesis Density, PHD)滤波器,PHD 在现阶段依旧

被应用在目标跟踪研究中^[5],接着 Vo 等提出了基数概率假设密度(Cardinalised Probability Hypothesis Density, CPHD)滤波器,如文献[6]应用和高斯概率假设密度(Gaussian Mixture Probability Hypothesis Density, GM-PHD)滤波器^[7-8]。

研究发现,PHD 滤波器可以处理目标的新生、存活和死亡。但是对于新生目标的处理必须要求新生目标强度已知,在处理问题时往往假设其已从量测中获得并已知。PHD 滤波器缺少在本质上检测新生目标的功能,而新生目标的检测是多目标跟踪中重要部分。针对新生目标跟踪问题,García-Fernández 等^[9]提出泊松多伯努利混合(Poisson Multi-Bernoulli Mixture, PMBM)滤

波器,并利用文献[10]中的概率生成函数(Probability Generating Functionals, PGFS)和函数导数推导出了基于共轭先验性质的 PMBM 滤波器。本文将其应用于新生目标跟踪研究中。

在 MTT 滤波中,考虑共轭先验是有优势的,在共轭先验中,后验分布可以明确地写成单目标贝叶斯更新的形式。PMBM 滤波器的共轭先验由泊松过程和多伯努利混合(Multi-Bernoulli Mixture, MBM)的并集构成。泊松部分表示在无杂波下从未检测到的目标(新生目标),MBM 部分表示至少检测过一次的目标(生存目标)。全局数据关联就是单目标的数据关联,每一个目标量测都只对应于一个目标,并且指定了目标基数上的分布而不是唯一基数。

本文提出一种基于 PMBM 滤波器的新生目标跟踪方法。针对多目标无虚警研究,不需要假设新生目标先验信息已知,仅根据量测信息来构建新生目标的强度信息。跟踪的简要流程为根据量测信息将泊松过程的量测构建为新生目标,将符合 MBM 的量测建立存活目标,并将两者分别进行预测、更新和修剪。并将本文算法与传统 GM-PHD 算法进行对比。

1 泊松多伯努利混合模型

1.1 泊松多伯努利 RFS 模型

基于 RFS 的方法中,目标状态和观测值以有限集的形式表示。系统在 k 时刻的状态被建模为一个集合 X_k ,在 k 时刻得到的一组测量值记作 Z_k ,包括杂波、目标产生的量测和未知的量测来源。到时刻为止接收到的所有测量集的序列记作^[4]。

通过将标签合并到目标状态中,使每个状态 $x \in X$ (X 为 RFS 的空间)被一个唯一的离散标签 $l \in L$ (L 是标记离散可数的 RFS 空间)扩充,可以从其未标记的版本形成一个标记的 RFS。假设 $\mathcal{L}(X)$ 为 X (带标签的多目标状态)的标签集合,当 $\delta_{|X|}(|\mathcal{L}(X)|) = 1$ 时有限子集 X 空间 $X \times L$ 具有不同的标签^[11]。

强度函数为 $\lambda(x)$ 的非齐次泊松点过程(Poisson Point Process, PPP)的 RFS 密度函数为^[12]:

$$f^{\text{PPP}}(X) = \exp(-\int \lambda(x) dx) \cdot \lambda^X \quad (1)$$

式中: x 为单个目标的状态; X 为多个目标的状态; $|X|$ 为集基数表示泊松分布; $x \in X$ 为独立同分布。泊松过程常用于未标记的 RFS 滤波器中的杂波和新生目标建模。

存在概率 r 和存在概率密度函数 $f(x)$ 的伯努利过

程的 RFS 密度函数为:

$$f(x) = \begin{cases} 1-r & X = \emptyset \\ r \cdot f(x) & X = \{x\} \\ 0 & \text{其他} \end{cases} \quad (2)$$

式中: $|X|$ 为集基数服从参数为 r 的伯努利分布。标记的伯努利随机有限集 X 是一个伯努利随机有限集 X 和标签 l 的增广组成对应于非空的伯努利分量 $x, X = \{(x, l)\}$ 或 $X = \emptyset$ 。伯努利过程可以获得目标存在和状态的不确定性,它也被用于标记 RFS 滤波器来模拟新生目标。

用多伯努利的 RFS 表示多个目标时,多伯努利的 RFS X 是独立伯努利 RFS X_i 的集合,有 $X = \cup_{i=1}^N X_i$ 且:

$$f^{\text{mb}}(x) = \sum_{\uplus_i^N X_i = X} \prod_{i=1}^N f_i(X_i) \quad (3)$$

式中: \uplus 不相交并集运算符; $f_i(X_i)$ 为状态 X_i 存在的密度函数。

1.2 贝叶斯滤波器递归

根据文献[6],可以用基数分布 $c(n)$ 和联合条件状态分布 $f_n(x_1, x_2, \dots, x_n | n)$ 表示为:

$$f(\{x_1, x_2, \dots, x_n\}) = c(n) \sum_{x \in \prod_n} f_n(x_1, x_2, \dots, x_n | n) \quad (4)$$

式中: x_i 是 x 的第 i 个分量。并且带标签的 RFS 和不带标签的 RFS 具有一样的基数分布。

在式(4)所示的 k 时刻的多目标分布,在给定 k' 时刻的所有量测条件下, k 时刻的状态集合的似然函数为 $f_{k|k'}(X_k | Z^{k'})$, $f_k(Z_k | X_k)$ 为 k 时刻量测的似然函数。根据文献[4],贝叶斯滤波器的状态更新似然函数为:

$$f_{k|k}(X_k | Z^k) \propto f_k(Z_k | X_k) f_{k|k-1}(X_k | Z^{k-1}) \quad (5)$$

式中: \propto 表示约等于。

贝叶斯滤波器状态预测似然函数表示为:

$$f_{k+1|k}(X_{k+1} | Z^k) = \int f_{k+1|k}(X_{k+1} | X_k) f_{k|k}(X_k | Z^k) dX_k \quad (6)$$

贝叶斯滤波器的积分集合为:

$$\int f(X) dX = f(\emptyset) + \sum_{n=1}^{\infty} \frac{1}{n!} \int f(\{x_1, x_2, \dots, x_n\}) d(x_1, x_2, \dots, x_n) \quad (7)$$

1.3 标准化点目标转换和量测模型

解决基于 RFS 的 MTT 问题的动态点目标转换模型有以下假设^[12]:

新生目标根据 PPP 过程建立,独立于生存目标。在每个时间步长目标保持生存概率 $P_s(x)$ 。目标下

一时刻的状态只取决于当前时刻的状态。目标运动遵循独立同分布马尔可夫过程,其状态转换密度为 $f_{k|k-1}(x_k|x_{k-1})$ 。

多目标模型的转移概率

$$f(X_{k+1}|X_k) = \sum_{S_k \uplus B_k = X_{k+1}} f_S^{\text{mb}}(S_k|X_k)f_B(B_k) \quad (8)$$

式中: $f_S^{\text{mb}}(\cdot|X)$ 是 MB 形式的生存目标的转移密度; $f_B(\cdot)$ 是新生目标的转移密度; S_k 表示 k 时刻的生存目标集; B_k 表示 k 时刻的新生目标集。

建立量测模型有以下假设:

每个目标生成的量测只对应于相应的目标,单目标量测似然函数为 $f_k(z_k|x_k)$ 。在每个时间步长中可能检测到目标也可能检测不到,目标检测概率为 $P_d(x)$ 。该传感器可以接收非目标(杂波)的测量(虚警)。在每个时间步长,杂波服从 PPP 强度为 $\lambda_c(z)$,独立于目标和目标生成的量测。

多目标量测模型的似然函数可以用卷积形式表示^[12]:

$$f_k(Z_k|X_k) = \sum_{T_k \uplus C_k = Z_k} f_k^{\text{mb}}(T_k|X_k)f_k^{\text{ppp}}(C_k) \quad (9)$$

式中: T_k 是 k 时刻目标生成量测; C_k 是 k 时刻杂波量测。

1.4 泊松多伯努利混合滤波器

根据文献[10],MTT 的 PMBM 过程的 RFS 密度函数是独立 PPP 和 MBM 分量的线性组合,其形式可表示为:

$$f(x) = \sum_{Y \uplus W = X} f^{\text{ppp}}(Y)f^{\text{mbm}}(W) \quad (10)$$

式中: Y 是尚未检测到的目标; W 是检测到至少一次的目标。对于 $Y \uplus W = X$ 已经检测到的目标,其分布可以描述为一个 MBM 的形式:

$$f^{\text{mbm}}(X) = \sum_{a = \{h_1, h_2, \dots, h_N\} \in \mathcal{A}} w_a \sum_{\forall X_i = X} \prod_{i=1}^N f_{h_i}(X_i) \quad (11)$$

式中: \mathcal{A} 表示每一个 MB 分量的集合; $a = \{h_1, h_2, \dots, h_N\}$ 为目标关联假设, N 为目标关联假设个数; w_a 为权重,满足 $\sum_{a = \{h_1, h_2, \dots, h_N\} \in \mathcal{A}} w_a = 1$ 。每一个 MB 分量都对应一个特定的数据关联。

每个数据关联假设都是由单个目标假设 $\{h_1, h_2, \dots, h_N\}$ 对应每个目标。假设存在但从未被检测到的目标被视为未知目标,用 PPP 分布表示。

在预测步骤中,描述已有轨迹的 MBM 和描述未知目标的 PPP 分别被单独预测。通过建立泊松出生模型,可以将新生目标的 PPP 合并到预测的 PPP 中。在更新步骤中,PPP 和 MBM 是独立更新的。为每一次量测建立两个单目标假设,然后通过漏检概率更新

PPP 强度。

2 线性高斯 PMBM 滤波算法

2.1 背景假设研究

在文献[9]的共轭先验概率中,MBM 有一个指标 j 。 j 对应一个全局假设,表示测量值与潜在目标之间可能存在的关联。全局假设可以用单目标假设来表示。单目标假设对应于每个可能探测到目标相关的一系列测量。给定一个单目标假设,这个可能被探测到的目标遵循伯努利分布。因此,每次测量都开始于一个新的单目标假设^[13]。在接下来的时间步长中通过将以前的单目标假设与当前的测量值或误检值联系起来去创建新的单目标假设。在没有不相关的量测并且一个量测只能分配给一个单一的目标假设下即全局假设是这些单目标的集合。

目标状态估计选择式(11)的 MBM 全局假设中最大的权重,则获得的指标为:

$$j^* = \arg \max_j \prod_{i=1}^n w_{j,i} \quad (12)$$

式中: j^* 的伯努利分量均值的存在概率大于阈值 Γ 。

2.2 预测

假设在前一个时间步长的后验中,泊松分量强度的后验高斯混合密度为:

$$\lambda^u(x) = \sum_{i=1}^{n_u} w_{u,i} \mathcal{N}(x; \bar{x}_{u,i}^p, P_{u,i}^p) \quad (13)$$

式中: $w_{u,i}$ 为第 i 个目标的后验权值; $\bar{x}_{u,i}^p$ 为第 i 个目标泊松先验均值; $P_{u,i}^p$ 为第 i 个目标泊松先验协方差; u 为后验泊松强度; n_u 为表示成泊松强度的目标数。

假设生存概率 P_s 恒定,转移密度函数 $g(x|y) = \mathcal{N}(x; \mathbf{F}y, \mathbf{Q})$, 其中: \mathbf{F} 为状态转移矩阵; \mathbf{Q} 为噪声矩阵。新生目标强度为:

$$\lambda^b(x) = \sum_{i=1}^{n_b} w_{b,i}^p \mathcal{N}(x; \bar{x}_{b,i}^p, P_{b,i}^p) \quad (14)$$

式中: $w_{b,i}^p$ 为第 i 个新生目标权值; $\bar{x}_{b,i}^p$ 为第 i 个新生目标泊松均值; $P_{b,i}^p$ 为第 i 个新生目标泊松协方差; n_b 为新生目标数。然后,根据文献[14]卡尔曼滤波预测步骤的已知结果,我们得到预测的强度是一个高斯混合形式:

$$\mu(x) = \lambda^b(x) + p_s \sum_{i=1}^{n_u} w_{u,i} \mathcal{N}(x; \mathbf{F}\bar{x}_{u,i}^p, \mathbf{F}P_{u,i}^p\mathbf{F}^T + \mathbf{Q}) \quad (15)$$

式中: \mathbf{F}^T 为 \mathbf{F} 的转置。

2.3 更新

假设 p_d 是常数, 概率密度函数 $p(z|x) = \mathcal{N}(z; \mathbf{H}x, \mathbf{R})$, 其中: \mathbf{H} 为观测矩阵; \mathbf{R} 为噪声协方差矩阵。将式(14)中新生目标泊松分量部分的预测强度重写为高斯形式, 得到目标高斯混合更新为:

$$\mu(x) = \sum_{i=1}^{n_\mu} w_{\mu,i} \mathcal{N}(x; \bar{x}_{\mu,i}, P_{\mu,i}) \quad (16)$$

式中: $\bar{x}_{\mu,i}$ 为第 i 个目标先验均值; $P_{\mu,i}$ 为第 i 个目标先验协方差。

从共轭先验更新中得到三种不同类型的更新: 未检测到目标的更新(泊松分量), 第一次检测到的潜在目标更新和已检测到的目标更新。泊松部分的更新比较容易。将未检测目标的更新强度式(16)乘以 $1 - p_d$ 。

(1) 第一次检测到的潜在目标更新(新生目标)。首先遍历所有的泊松先验, 并对量测值上执行椭圆形门控如文献[9]选择, 以降低计算复杂度。对于那些可以根据门控输出新轨迹的量测, 我们执行贝叶斯更新。 z 为量测, 并给出了 $r^p(z)$ 存在的伯努利分量和目标状态密度函数 $p^p(x|z)$ 如:

$$r^p(z) = e(z)/\rho^p(z) \quad (17)$$

$$p^p(x|z) = p(z|x)\mu(x)/e(z) \quad (18)$$

其中:

$$e(z) = p_d \int p(z|x)\mu(x) dx \quad (19)$$

$$\rho^p(z) = e(z) + c(z) \quad (20)$$

式中: $c(\cdot)$ 为杂波量测; $e(z)$ 为存在量测。为了降低计算复杂度, 将式(19)中的高斯混合函数近似为高斯函数, 并进行矩阵匹配。确定新创建的 MBM 的假设权值, $\rho^p(z)$ 是假设权值 $w_{j,i}$ 首次在全局假设 j 下检测到潜在目标测量 z 。如果全局假设 j 不考虑这个可能被探测到的目标 $w_{j,i} = 1$, 则将其存在概率设为 0。

(2) 已检测到的目标更新(生存目标)。通过式(11)的遍历创建单一目标的假设, $r_{j,i}$ 为全局假设 j 的第 i 个目标的生存概率, $w_{j,i}$ 为全局假设 j 的第 i 个目标的权重。可得已检测到的目标的高斯概率假设密度为:

$$p_{j,i}(x) = \mathcal{N}(x; \bar{x}_{j,i}, P_{j,i}) \quad (21)$$

2.4 基于 k-Best 方法全局假设的选择

对于每一个全局假设 j 在前一个时间步长中, 必须通过所有可能的数据关联假设, 从而产生更新的全局假设。这种全局假设的大量增加是共轭先验计算的瓶颈。然而, 基于标记 RFS 和 MHT 的文献, 通过使用 Murty 算法^[15] 修剪假设的数量来近似这一更新。通过该算法, 可以在不评估所有新生成的全局假设的情况

下, 为给定的全局假设 j 选择权值最高的 k 个新的全局假设。对于全局假设 j , 所有的量测(不包括门限滤除量测)必须与全局假设 j 中的现有轨迹相关联或与新轨迹相关联, 并且没有未分配的测量。然后利用共轭先验的更新权值构造相应的代价矩阵。假设通过门限后在全局假设 j 中有 n_0 个旧轨迹, m 个量测 z_1, z_2, \dots, z_m 。代价矩阵为:

$$\mathbf{C} = -[\ln(\mathbf{W}_{ot}, \mathbf{W}_{nt})] \quad (22)$$

式中: $\mathbf{W}_{nt} = \text{diag}(\rho^p(z_1), \rho^p(z_2), \dots, \rho^p(z_m))$, \mathbf{W}_{nt} 表示潜在检测目标的权值矩阵; $\mathbf{W}_{ot} \in \mathbf{R}^{m \times n_j}$ 表示生存目标的权值矩阵, n_j 为全局假设 j 中前一时刻潜在检测到的目标个数。 \mathbf{W}_{ot} 中的 p, i 表示第 i 个目标相关联的第 p 个量测。 \mathbf{W}_{ot} 为:

$$w_{j,i} \rho_{j,i}(\{z_p\}) / \rho_{j,i}(\emptyset) = \frac{w_{j,i} r_{j,i} p_d \mathcal{N}(z_p; \mathbf{H} \bar{x}_{j,i}, S_{j,i})}{w_{j,i} (1 - r_{j,i} + r_{j,i} (1 - p_d))} \quad (23)$$

在 $\rho_{j,i}(\emptyset)$ 的权值标准化之前不分配新生和生存目标的量测的假设权值。这样做是为了利用 Murty 算法有效地获得 k-best 全局假设, 但不改变实际的权值, 权值没有标准化。每一个新的全局假设都可以将假设 j 表示成 $m \times (m + n_0)$ 由 0 或 1 构成的分配矩阵 \mathbf{S} 。使用 Murty 算法最小化矩阵 $\text{tr}(\mathbf{S}^T \mathbf{C})$, 选择 k-Best 全局假设。对于全局假设 j , 选择 $\mathbf{k} = [N_h \cdot w_j]$, $w_j \propto \prod_{i=1}^n w_{j,i}$, N_h 为全局假设最大值。

2.5 线性高斯 PMBM 算法流程

步骤 1 根据当前时刻量测集 Z 和前一时刻 PMBM 后验参数得到当前时刻 PMBM 后验参数。

步骤 2 进行多目标预测。

步骤 3 进行多目标运动状态更新。

步骤 4 修剪。剪去权值低于阈值的成分来修剪泊松部分。保持 N_h 最大的全局假设来修剪全局假设。删除存在概率低于阈值或不出现在修剪后的全局假设中的伯努利分量。

3 仿真实验

通过蒙特卡洛实验对比 PMBM 滤波器与高斯混合 PHD 滤波器^[16] 的仿真结果。实验中有四个目标如图 1 所示, 四个目标都是在时间步长为 1 时刻产生的, 在整个模拟过程中都是存活的, 除了在时间步骤 40 死亡的直线目标, 此时所有目标都很接近。目标初始位置有一个十字表示。观测区间为 $[0, 300 \text{ m}] \times [0, 300 \text{ m}]$; 目标状态 $[p_x, v_x, p_y, v_y]^T$, (p_x, p_y) 为位置信

息, (v_x, v_y) 为速度信息。目标根据强度为 0.005 泊松过程产生, 并服从高斯密度均值 $[100, 0, 100, 0]^T$ 协方差 $\text{diag}([150^2, 1, 150^2, 1])$ 的分布, 目标遵循匀速的线性高斯模型, 状态方程 $\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{w}_t$, 其中过程噪声 $\mathbf{w}_t \sim \mathcal{N}\{0, \mathbf{Q}\}$, $\mathbf{F} = \mathbf{I}_2 \otimes \begin{pmatrix} 1 & T \\ 0 & 1 \end{pmatrix}$, $\mathbf{Q} = q\mathbf{I}_2 \otimes \begin{pmatrix} T^3/3 & T^2/2 \\ T^2/2 & T \end{pmatrix}$ 观测方程 $\mathbf{z}_t = \mathbf{H}\mathbf{x}_t + \mathbf{v}_t$, 其中: 观测噪声 $\mathbf{v}_t \sim \mathcal{N}\{0, \mathbf{R}\}$; $\mathbf{H} = \mathbf{I}_2 \otimes (1 \ 0)$, $\mathbf{R} = \mathbf{I}_2$; \otimes 为克罗内克积; $q = 0.01$; $T = 1 \text{ s}$; $p_s = 0.99$ 。杂波服从强度为 $\lambda_c = 10$ 的泊松分布, $p_d = 0.9$ 。全局假设最大值 $N_h = 200$, 存在估计阈值 $\Gamma = 0.4$ 。泊松部分的修剪阈值为 10^{-5} , 多伯努利混合部分的修剪阈值为 10^{-4} , 椭圆门限阈值为 20。采用广义最优模型分配 (Generalised Optimal SubPattern Assignment, GOSPA) 距离评价算法^[17]。且参数 $\alpha = 2$ 、 $p = 2$ 、 $c = 10$ 。仿真对比算法结果如图 2 所示。



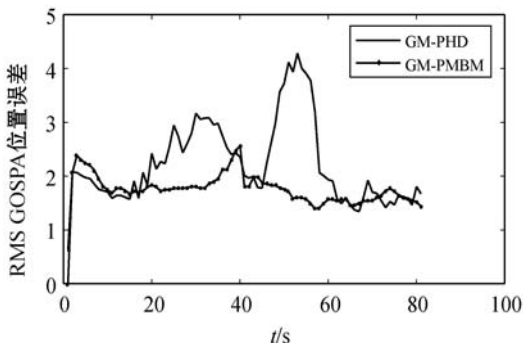



图 1 目标真实轨迹



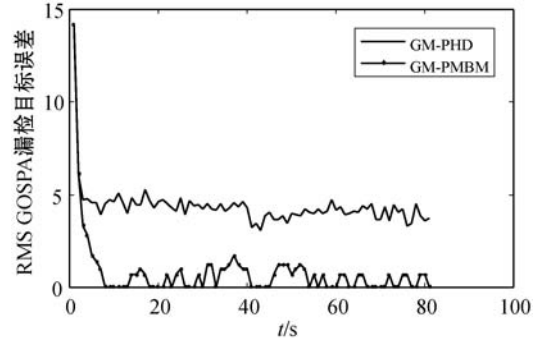
(a) RMS GOSPA 误差



(b) RMS GOSPA 位置误差



(c) RMS GOSPA 虚假目标误差



(d) RMS GOSPA 漏检目标误差

图 2 GOSPA 均方根四种误差算法对比

表 1 给出了两种算法 GOSPA 四种参数的对比。在本文算法 GOSPA 的误差均方根减少 47%, 位置误差均方根减少 24%, 错检目标误差均方根减少 32% 和漏检误差均方根减少 57%。仿真结果显示, 本文算法不仅跟踪精度有所提高, 而且还分别针对不同误差进行对比, 可以进一步研究更好改进途径。

表 1 GOSPA 均方根误差算法对比

算法	RMS GOSPA 误差	RMS GOSPA 位置误差	RMS GOSPA 虚假目标误差	RMS GOSPA 漏检目标误差
GM-PHD	5.332 1	2.352 9	1.600 5	4.509 2
GM-PMBM	2.825 1	1.777 6	1.085 8	1.908 4

表 2 给出了两种算法时间上的对比。从平均每次运行时间可看出, 本文算法时间消耗为传统 GM-PHD 的 4.55 倍。GM-PHD 需要新生目标的先验信息, 不需要重新去构造出新生目标的强度, 从而在时间上应用减少。但是需要先验信息的假设是不合理的, 严重依赖先验信息, 容易产生较大误差, 从而限制了其应用。本文算法以时间消耗为代价提高了目标的跟踪性能。本文应用 MATLAB 仿真没有进行算法优化, 下一步以计算机的并行处理此方面进行时间改进途径。

表 2 两种算法运行时间对比 单位:s

算法	100 次仿真总时间	平均每次运行时间
GM-PHD	326.771 3	3.267 7
GM-PMBM	1487.441 6	14.874 4

4 结 语

针对传统 GM-PHD 滤波算法需要先验的新生目标强度,提出基于 PMBM 滤波算法。该算法由泊松过程和多伯努利混合形式的并集组成,将当前时刻量测划分为新生目标量测和存活目标量测,并且分别进行线性高斯形式的泊松强度的新生目标和多伯努利混合分布的生存目标预测、更新和修剪。从实验仿真效果来看,本文算法可以在新生目标未知的情况下有效地进行跟踪,其跟踪精度、误差优于传统的 GM-PHD 滤波算法。接下来可以用该算法去解决航迹初始建立问题和形成问题。

参 考 文 献

- [1] 罗建华. 基于改进提升模型的视频目标跟踪算法[J]. 计算机应用与软件,2018,35(1):261-263,311.
- [2] 陈波. 一种改进的迭代无迹卡尔曼滤波算法[J]. 计算机应用与软件,2019,36(10):274-278.
- [3] 隋靓,党建武. 基于运动目标轨迹的高速公路异常事件检测算法研究[J]. 计算机应用与软件,2018,35(1):246-252.
- [4] Mahler R P. Statistical multisource-multitarget information fusion[M]. Artech House,2007.
- [5] Zhu Q, Li T, Pan J, et al. The modified probability hypothesis density filter with adaptive birth intensity estimation for multi-target tracking in low detection probability[J]. IEEE Access,2020,8:43690-43710.
- [6] García-Fernández A F, Svensson L. Trajectory PHD and CPHD filters[J]. IEEE Transactions on Signal Processing, 2019,67(22):5702-5714.
- [7] 周天,张丽红,杜伟东,等. 声呐图像多目标跟踪高斯滤波算法[J]. 哈尔滨工程大学学报,2020,41(5):691-697.
- [8] 张腾,邢孟道,曹晨,等. 红外数据辅助的 GM-PHD 滤波工程优化算法[J]. 现代雷达,2019,41(3):58-62.
- [9] García-Fernández A F, Williams J L, Granström K, et al. Poisson multi-bernoulli mixture filter: Direct derivation and implementation[J]. IEEE Transactions on Aerospace and Electronic Systems,2018,54(4):1883-1901.
- [10] Williams J L. Marginal multi-bernoulli filters: RFS derivation of MHT, JIPDA, and association-based member[J]. IEEE Transactions on Aerospace and Electronic Systems, 2015,51(3):1664-1687.
- [11] Vo B T, Vo B N. Labeled random finite sets and multi-object conjugate priors[J]. IEEE Transactions on Signal Processing, 2013,61(13):3460-3475.
- [12] Xia Y, Granstrom K, Svensson L, et al. Performance evaluation of multi-bernoulli conjugate priors for multi-target filtering[C]//2017 20th International Conference on Information Fusion(Fusion),2017:1-8.
- [13] Kurien T. Issues in the design of practical multitarget tracking algorithms[M]. Artech House,1990.
- [14] Särkkä S. Bayesian filtering and smoothing[D]. Cambridge, 2013.
- [15] García-Fernández A F, Xia Y, Granström K, et al. Gaussian implementation of the multi-Bernoulli mixture filter[C]//2019 22th International Conference on Information Fusion, 2019:1-8.
- [16] Vo B N, Ma W K. The Gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on Signal Processing,2006,54(11):4091-4104.
- [17] Rahmathullah A S, García-Fernández á F, Svensson L. Generalized optimal sub-pattern assignment metric [C]//2017 20th International Conference on Information Fusion, 2017.

(上接第 265 页)

参 考 文 献

- [1] 吴雨婷,叶勇,骆宏敏. 基于蚁群算法的速冻蔬菜配送路径优化研究[J]. 洛阳理工学院学报(自然科学版), 2020,30(1):67-72.
- [2] 杨德成,李凤岐,王祎,等. 智能 3D 打印路径规划算法[J]. 计算机科学,2020,47(8):267-271.
- [3] 陈康政,刘丽冰,杨泽青,等. 基于 HPSO 算法的 CNC 在线检测路径规划[J]. 组合机床与自动化加工技术,2020(3):78-82.
- [4] 张文拴,徐海军,闫哲. 蚁群算法研究及其在航海上的应用[J]. 广州航海学院学报,2018,26(4):66-70.
- [5] 杨健,董力勇,王鸿,等. 应用分层优化法的多协作无人机任务规划方法[J]. 指挥与控制学报,2019,5(1):41-46.
- [6] Cook S A. The complexity of theorem-proving procedures [C]//3rd Annual ACM Symposium on Theory of Computing, 1971:151-158.
- [7] Karp R M. Reducibility among combinatorial problems[M]//Complexity of Computer Computations. Plenum Press, 1972: 85-104.
- [8] 唐昊,刘畅,杨明,等. 考虑电网调峰需求的工业园区主动配电系统调度学习优化[J]. 自动化学报,2021,47(10): 2449-2463.
- [9] 田威,焦嘉琛,李波,等. 航空航天制造机器人高精度作业装备与技术综述[J]. 南京航空航天大学学报,2020,52(3):341-352.
- [10] 陈亦令,边保军. 稳定 Hawkes 过程下的保险公司分红问题[J]. 高校应用数学学报,2020,35(2):158-168.
- [11] Bellman R. Dynamic programming treatment of the traveling salesman problem[J]. Journal of the ACM,1962,9(1):61-63.