

多扩展目标滤波器的量测集划分算法

韩玉兰¹, 任重义², 韩崇昭¹

(1. 西安交通大学 电子与信息工程学院, 陕西 西安 710049; 2. 宁夏大学 机械工程学院, 宁夏 银川 750021)

摘 要: 针对不同扩展目标产生的量测密度差别较大时的量测集划分问题, 为扩展目标概率假设密度(PHD)滤波器提出了一种基于共享最近邻(SNN)相似度的量测集划分算法。量测间的SNN相似度可体现量测在量测空间局部分布情况, 考虑了量测周围的量测信息, 因此提出的SNN相似度划分法能够较好地划分量测密度差别较大的量测集, 进而提高了扩展目标的跟踪性能, 且基于提出的划分算法的PHD滤波器计算量也所减少。

关键词: 目标跟踪; 扩展目标; 扩展目标概率假设密度(PHD)滤波器; 量测集划分; SNN相似度

中图分类号: TN274

文献标识码: A

A Measurement Set Partitioning Algorithm for Extended Target Gaussian-mixture Probability Hypothesis Density Filter

HAN Yulan¹, REN Zhongyi², HAN Chongzhao¹

(1. School of Electronics and information Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. School of Mechanical Engineering, Ningxia University Yinchuan 750021, China)

Abstract: The partitioning method based on distance does not work well when the densities of measurements from different extended targets are very different, and thus reduce the performance of the extended target probability hypothesis density (PHD) filter. Based on the share nearest neighbors (SNN) similarity, this paper presents a measurement set partitioning approach, which could work well in the situation that the densities of measurements from different extended targets are very different and further could enhance the tracking performance of the filter based on the proposed method. The SNN similarity that incorporates the neighboring measurement information is introduced instead of the distance between measurements used in the measurement set partitioning, and thus it is relatively insensitive to variation in measurement density. Although calculating the SNN similarity consume some time, the resulting PHD filter based on the proposed partitioning approach does not cause more computational burden due to the lesser number of the resulting partitions. Especially in high clutter scenarios, a significant reduction in computational complexity can be achieved. Simulation results demonstrate the superiority of the filter based on the proposed partitioning approach.

Key words: target tracking; extended target; PHD filter; measurement set partitioning; share nearest neighbors similarity

0 引言

数据关联是传统多点目标跟踪算法的重要环节, 对估计结果的性能产生重要的影响。经典数据关联算法有最近邻法、概率多假设(PMHT)、联合概率数据关联(JPDA)^[1]等。另一类的多目标跟踪算法是基于随机有限集理论的, 如扩展目标概率假设密度(PHD)滤波器^[2]、基元 PHD(CPHD)滤波

器^[3]、高斯混合 PHD(GMPHD)滤波器^[4]、粒子 PHD 滤波器^[5]等。这类滤波器不需要数据关联即可递推获得目标的数目及状态。Mahlar、Orguner、Granstrom 分别将 PHD、CPHD、GMPHD 滤波器推广到多扩展目标跟踪中^[6-8]。在理论上, 基于随机有限集的扩展目标滤波器需要考虑量测集的所有可能划分, 但所有可能的划分个数随目标个数的增加

收稿日期: 2015-05-04

基金项目: 宁夏回族自治区自然科学基金资助项目(NZ13047)

作者简介: 韩玉兰(1982-), 女, 河南新乡人, 博士生, 主要从事扩展目标跟踪与信息融合的研究。E-mail: orchis99@stu.xjtu.edu.cn。韩崇昭, 男, 教授, 主要从事多源信息融合、多目标跟踪、随机系统的研究。

急速增大。文献[8]中提出了距离划分法、距离-辅助划分法来获得所有划分的子集。

文献[8]中的划分算法都是基于量测之间的距离,在扩展目标产生量测的密度较大时不能获得较好的量测集划分结果,从而进一步影响了扩展目标PHD滤波器的性能。针对这个问题,本文提出了一种基于共享最近邻(SNN)相似度的量测集划分算法。由于两量测之间的SNN相似度^[3]不仅仅与这两个量测有关,而且与两量测的K最近邻都有关系,因此本文提出的量测集划分对量测密度的变化不敏感。

1 基于SNN相似度的划分算法

1.1 基于距离划分的分析

为减少计算量,文献[8]中基于量测间距提出了距离划分法、距离-辅助划分法来获得所有划分的子集。距离划分法和距离-辅助划分法的划分个数仍会随着量测个数的增加急速增大。但在扩展目标PHD滤波器的更新估计过程中,由于有些划分的不合理性导致其权重很小,对目标估计贡献几乎不产生任何影响,却带来了很大的计算负荷。而且有这种问题的不合理划分所在总划分个数的比重很大。当杂波密度较大时,这个问题会更严重。

当不同扩展目标的量测密度相差较大时,上述的基于距离的划分无法获得较理想的效果。且在有些情况下,根本不存在可以将不同目标量测划分开的阈值。图1为源于3个扩展目标的不同密度的量测,选择的阈值较小时,会将源于1个扩展目标1的量测分成几个簇,如图2所示。若再选取稍大的阈值,则会将源于目标2、3的量测置于同一簇中,且此时源于扩展目标1的量测仍被分成不同的簇,如图3所示。图2、3中不同的形状的点表示不同的簇中的量测。




图1 源于3个扩展目标的量测




图2 距离划分法在某一较小阈值下得到的划分结果




图3 距离划分法在某稍大阈值下得到的划分结果

1.2 基于SNN相似度的划分算法

本文基于量测间的SNN相似度提出了一种新的量测集划分算法,并称为SNN相似度划分算法。

本文采用文献[9]中的定义方式对SNN相似度进行定义,并将这个定义应用到量测之间,即对于量测 z_i 和 z_j ,若量测 z_i 的K最近邻中包含量测 z_j ,且量测 z_j 的K最近邻中包含量测 z_i ,则量测 z_i 和 z_j 的SNN相似度为量测 z_i 与 z_j 的K最近邻中相同量测的个数,则

$$S(z_i, z_j) = |N(z_i) \cap N(z_j)| \quad (1)$$

式中: $N(z)$ 为量测 z 的K个最近邻; $|A|$ 为集合A的元素个数。否则,量测 z_i 和 z_j 的SNN相似度为0。

SNN相似度划分算法将所有SNN相似度大于等于阈值 s_1 的量测对置于同一簇中,不同的相似度阈值 s_1 获得不同的划分。具体实现步骤如下:

1) 计算量测间距。对量测集中的所有量测,计算两量测间的距离。

2) 计算K最近邻。对每个量测找到其K个最近邻,计算两量测间的SNN相似度。

3) 计算相似度矩阵。根据SNN相似度,建立 N_m 维SNN相似度矩阵 S ,其中 N_m 为量测集中的量测个数。

4) 选择相似度阈值集 $\{s_l\}_{l=1}^N$ 。由于量测之间的 SNN 相似度取值范围为 $[0:K-1]$, 相似度阈值从集合 $\{0:K-1\}$ 中选择。本文将 $\{s_l\}_{l=1}^N$ 取为 $\{0:K-1\}$ 。

5) 对量测集进行划分。对每个给定的相似度阈值, 对量测集进行划分获得 $K-1$ 个划分结果。

对于给定的阈值 s_l , 量测集划分法可描述为将 $S \geq s_l$ 的元素用 1 代替, 其他的用 0 取代, 形成的矩阵记为 S_{th} ; 将矩阵 S_{th} 中同一个 1 连通域对应的量测置于同一个簇, 连通域的个数即为簇的个数。

由式(1)可知, 两量测的 SNN 相似度不但可体现其间距是否较近, 还能体现它们周围量测的情况。可根据量测密度大小自动进行缩放, 当源于一个目标的量测分散得较开时, 则这些量测的 K 近邻所形成的区域较大, 反之较小。因此本文提出的 SNN 相似度划分算法对密度大小不敏感。




图4 SNN 相似度划分算法在某阈值下的划分结果

采用本文提出的 SNN 相似度划分算法对图 1 中的量测集进行划分, 设置 $K=20$ 。所得划分中包含正确的划分结果, 如图 4 所示(不同形状的点表示不同簇中的量测)。

1.3 SNN 相似度划分算法的参数选择

SNN 相似度划分中需事先对参数 K 进行设置。若 K 设置过小, 由于其关注 SNN 相似度的局部变化, 导致易将源于同一的量测分成多个簇; 若设置太大, 则局部变化对结果影响很小, 易将源于多个目标的量测置于同一簇中。

为了能选择合适的 K 值, 在源于同一目标的量测服从高斯分布及均匀分布、个数服从泊松分布的情况下, 对在不同的 K 下获得的结果进行评价, 以划分中错误划分的量测个数作为评价指标。统计 K 在哪些范围下 SNN 相似度划分法得到的划分中包含正确或接近正确的划分, 统计结果如表 1 所示。

表1 参数 K 的范围

每个目标产生量测个数的均值	K 的合适范围
10	4~6
15	6~12
20	6~16
30	6~16
40	6~18
50	6~22
100	8~45

注: 每个扩展目标产生量测个数的均值相同。

由表 1 可知, 单个目标产生量测个数的均值越大, 对 K 的要求也宽松。当单个目标产生量测个数的均值较小, SNN 相似度划分法很难得到理想的划分结果。在选择合适的 K 值情况下, 即使源于不同目标的量测间的密度差别较大时, 也能获得较理想的划分结果。

2 仿真

这里扩展目标 PHD 滤波器采用高斯混合的实现方式, 设置了量测密度差别较大及高杂波环境下的仿真两个仿真场景。

2.1 仿真场景设置

对 $[1\ 000, 1\ 000] \times [1\ 000, 1\ 000]$ (m^2) 二维空间的监测区域中的扩展目标进行跟踪。扩展目标的状态 $\mathbf{x}_k = [x_k, y_k, v_k^x, v_k^y]^T$ 由目标位置 (x_k, y_k) 和速度 (v_k^x, v_k^y) 组成, $[\cdot]^T$ 为矩阵 $[\cdot]$ 的转置。

扩展目标的状态 $\mathbf{x}_k^{(i)}$ 演化服从线性高斯模型

$$\mathbf{x}_{k+1}^{(i)} = \mathbf{F}_k \mathbf{x}_k^{(i)} + \mathbf{G}_k \mathbf{w}_k^{(i)} \quad (2)$$

式中: $i=1, \dots, N_{x,k}$, $N_{x,k}$ 为 k 时刻扩展目标的个数; $\mathbf{w}_k^{(i)}$ 是均值为 0 的协方差 $\mathbf{Q}_k^{(i)}$ 的量测噪声。

源于目标 j 的量测的产生可由下式描述, 则

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k^{(j)} + \mathbf{v}_k \quad (3)$$

式中: $\mathbf{v}_k$ 为协方差 $(\mathbf{R}_k)$ 的高斯白噪声。各目标量测的产生互不相关。

目标演化方程和量测模型的抽样间隔 $T=1\text{ s}$, 过程协方差 $\mathbf{Q}_k = (2m/s)^2 \mathbf{I}_2$, $\mathbf{I}_2$ 为二维单位阵; $\mathbf{R}_k = (20m)^2 \mathbf{I}_2$, 其他参数设置为

$$\mathbf{F}_k = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (4)$$

$$G_k = \begin{bmatrix} \frac{T^2}{2} & 0 \\ 0 & \frac{T^2}{2} \\ T & 0 \\ 0 & T \end{bmatrix} \quad (5)$$

$$H_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (6)$$

目标生存概率 $p_s = 0.99$, 检测概率 $p_n = 0.99$, 目标新生强度为

$$v_h(x) = 0.1H(x; m_h^1, P_h) + 0.1H(x; m_h^2, P_h) \quad (7)$$

式中: $m_h^1 = [250, 250, 0, 0]^T$, $m_h^2 = [-250, 250, 0, 0]^T$, $P_h = \text{diag}\{[100, 100, 25, 25]\}$ 。衍生强度为

$$v_p(x) = 0.05H(x; \xi, P_p) \quad (8)$$

式中: $P_p = \text{diag}\{[100, 100, 400, 400]\}$; ξ 为自体目标的状态。

2.2 仿真结果

由于 PHD 滤波器不能提供航迹信息, 无法直接用传统的均方根误差 (RMSE) 对目标状态进行评估。这里借鉴近几年 PHD 滤波器的常用的综合评估指标 OSPA^[10] 中的状态评估部分作为目标状态的平均 RMSE。实验结果是在 100 次蒙特卡洛实验下获得的结果。

2.2.1 源于不同目标的量测密度不同

监测区域中有量测扩展目标, 航迹如图 5 所示。每个目标的量测个数服从均值为 20 的泊松分布。目标 2 的量测密度为目标 1 的 5 倍, 每个目标的量测服从高斯分布。杂波在整个监测区域服从均匀分布, 个数服从均值为 10 的泊松分布。




图 5 目标航迹

图 6、7 为不同量测集划分算法的 PHD 滤波器目标个数估计和平均 RMSE。由图 6、7 可知, 在采用距离-辅助划分法比采用距离划分法的滤波器的性能稍好, 但都不理想。而本文采用的 SNN 相似度分割法的滤波器的目标估计个数更接近真实值, 状态估计误差明显小于采用距离划分法和距离-辅助划分法的滤波器。特别是在两个目标相距较近时

(45~60 s), 采用 SNN 相似度分割算法的滤波器性能优于采用其他两种划分法的滤波器。这是由于在两个目标的量测密度差别较大, 采用距离划分法和距离-辅助划分法对量测集进行划分, 很可能划分结果中的所有划分均与实际情况相差较大, 进而引起对目标个数和状态估计效果不理想。图中, DP 为距离划分法, DPSP 为距离-辅助划分法, SNNSP 为本文提出的 SNN 相似度划分法。




图 6 不同量测集划分算法的 PHD 滤波器目标个数估计




图 7 不同量测集划分算法的 PHD 滤波器的平均 RMSE

距离划分法和距离-辅助划分法的划分个数会随着量测个数的增加而迅速增加, 但 SNN 相似度划分法的划分个数取决于 K 的大小, K 受量测个数的影响并不大, 因此其划分个数较小。图 8 所示的 SNN 相似度划分法的划分个数明显小于其他两种划分算法。虽然在 SNN 相似度的划分法需要进行 SNN 相似度的计算, 但由于其划分个数较少, 所需时间并不比距离划分法多, 如图 9 所示。而 SNN 相似度划分法和距离划分法所需时间明显小于距离-辅助划分法, 这是由于距离-辅助划分法需对距离划分中所划分的所有簇进行处理。而 PHD 滤波器的状态递推所需时间主要取决于划分中的所有簇的个数, 因此采用距离划分法和距离-辅助划分法的滤波器状态递推所需时间明显大于采用 SNN 相似度划分的滤波器, 如图 10 所示。本文仿真实验是在 i5-4570 3.2 GHz 处理器、4 GB 内存的 Matlab2010 版本下的运行结果。




图 8 不同量测集划分算法的划分个数




图9 不同量测集划分算法所需的时间




图10 不同量测集划分算法的 PHD 滤波器所需时间

2.2.2 高杂波环境

杂波量测个数的均值为 40 的泊松分布,为第一个仿真场景的 4 倍,目标个数、航迹均与第一个场景设置相同。为了体现在高杂波环境下的性能,这里设置两个目标的量测密度相同。

杂波在监控区域服从均匀分布,但由于出现的随机性使距离阈值的个数增加,导致了距离划分法和距离-辅助划分法的划分个数也迅速增加。距离划分法和距离-辅助划分法的划分个数约为 SNN 相似度划分法的 10 倍(见图 11)。另外,由于杂波量测间距相距较远,在距离划分法和距离-辅助划分法的划分中趋向于单独的一个杂波量测处于一个簇中,使总的簇的个数与远大于 SNN 相似度划分法,如图 12 所示。因此采用距离划分法和距离-辅助划分法的 PHD 滤波器的状态递推所需时间也远大于采用 SNN 相似度划分法的滤波器,如图 14 所示。由图 15、16 可知,采用 SNN 相似度划分法的 PHD 滤波器目标个数估计更接近真实值,其状态估计误差也较小。




图11 不同量测集划分算法的划分个数




图12 不同量测集划分算法的簇的总个数




图13 不同量测集划分算法所需的时间




图14 不同量测集划分算法的 PHD 滤波器所需时间




图15 不同量测集划分算法的 PHD 滤波器目标个数估计




图16 不同量测集划分算法的 PHD 滤波器的平均 RMSE

3 结束语

本文为扩展目标 PHD 滤波器提出了一种基于 SNN 相似度的量测集划分算法。采用提出划分算法的滤波器在源于不同目标的量测密度相差较大、高杂波及有相距较近的目标的情况下,仍可以获得较好目标个数和状态估计。且其计算量较小,特别是在杂波环境下降低了量测集划分和滤波器的滤波时间。

参考文献:

- [1] 韩崇昭,朱洪艳,韩崇昭,等.多源信息融合[M].北京:清华大学出版社,2010.
- [2] MAHLER R. Multitarget bayes filtering via first-order multitarget moments[J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1152-1178.
- [3] VO B T, VO B N, CANTONI A. The cardinalized probability hypothesis density filter for linear gaussian multi-target models[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1224-1245.
- [4] VO B N, MA W K. The gaussian mixture probability hypothesis density filter[J]. IEEE Transactions on

- Signal Processing, 2006, 54(11): 4091-4104.
- [5] VO B N, SUMEETPAL S, DOUCET A. Sequential Monte carlo methods for multitarget filtering with random finite sets[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1224-1245.
- [6] MAHLER R. PHD filters for nonstandard targets, I: extended targets[C]//Seattle: Proceedings of the International Conference on Information Fusion, 2009: 915-921.
- [7] ORGUNER U, LUNDQUIST C, GRANSTROM K. Extended target tracking with a cardinalized probability hypothesis density filter[C]//Chicago: Proceedings of the 14th International Conference on Information Fusion, 2011: 1-8.
- [8] GRANSTROM K, LUNDQUIST C, ORGUNER U. Extended target tracking using a gaussian mixture PHD filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2012, 48(4): 3268-3286.
- [9] JARVIS R A, PATRICK E A. Clustering using a similarity measure based on shared nearest neighbors [J]. IEEE Transactions on Computers, 1973, C-22(11): 1025-1034.
- [10] RISTIC B, VO B N, CLARK D, et al. A metric for performance evaluation of multi-target tracking algorithms[J]. IEEE Transactions on Signal Process, 2011, 59(7): 3452-3457.

(上接第 602 页)

参考文献:

- [1] 张小宁, 陈智军, 宣建青, 等. 乐甫波传播特性研究[J]. 压电与声光, 2011, 33(2): 174-177.
ZHANG Xiaoning, CHEN Zhijun, XUAN Jianqing, et al. Research on propagation characteristics of Love wave[J]. Piezoelectrics & Acoustooptics, 2011, 33(2): 174-177.
- [2] XIA Jianghai. Estimation of near-surface shear-wave velocities and quality factors using multichannel analysis of surface-wave methods[J]. Journal of Applied Geophysics, 2014, 103: 140-151.
- [3] 文常保, 朱长纯, 巨永锋, 等. 碳纳米管聚苯胺薄膜 SAW SO₂ 传感器的实验研究[J]. 压电与声光, 2009, 31(2): 157-160.
WEN Changbao, ZHU Changchun, JU Yongfeng, et al. Experimental study on SAW SO₂ sensor based on carbon nanotube-polyaniline films [J]. Piezoelectrics & Acoustooptics, 2009, 31(2): 157-160.
- [4] MATATAGUI D, FERNÁNDEZ M J, FONTECHA J, et al. Love-wave sensor array to detect, discriminate and classify chemical warfare agent stimulants[J]. Sensors & Actuators B: Chemical, 2012, 175: 173-178.
- [5] KUNDU S, MANNA S, GUPTA S. Love wave dispersion in pre-stressed homogeneous medium over a porous half-space with irregular boundary surfaces[J]. International Journal of Solids and Structures, 2014, 51(21/22): 3689-3697.
- [6] KANNAN T. Finite element analysis of surface acoustic wave resonators[D]. Saskatchewan: University of Saskatchewan, 2006.
- [7] ZHAO Yigui, LIU Ming, LI DongMei, et al. FEM modeling of SAW organic vapor sensors[J]. Sensors and Actuators A: Physical, 2009, 154(1): 30-34.
- [8] AULD B A. Acoustic fields and waves in solids[M]. New York: Wiley-Interscience, 1973.
- [9] HAN Kui, YUAN Y J. Mass sensitivity evaluation and device design of a LOVE wave device for bond rupture biosensors using the finite element method[J]. IEEE Sensors Journal, 2014, 14(8): 2601-2608.
- [10] EL GOWINI M M, MOUSSA Walied A. A reduced three dimensional model for SAW sensors using finite element analysis[J]. Sensors, 2009, 9(12): 9945-9964.