

基于分布式 BLUE 的多雷达数据融合方法

付 莹^{1a,1b,2}, 孙永健^{1b,3}, 汤子跃^{1b}

(1. 空军预警学院 a. 研管大队; b. 空天基预警监视装备系, 武汉 430019;
2. 中国人民解放军 95333 部队, 长沙 410114; 3. 北京无线电测量研究所, 北京 100039)

摘 要: 针对线性系统与非线性观测的混合跟踪融合问题, 推导目标匀加速运动时的三维最佳线性无偏估计(BLUE)滤波器, 给出基于分布式 BLUE 滤波的多雷达数据融合方法。由各单元雷达对直角坐标系下的目标状态进行 BLUE 估计, 对多部雷达的目标状态在融合中心进行融合估计, 采用位置、速度均方根误差和平均归一化估计误差平方作为融合性能评价标准。仿真结果表明, 与基于 NC 的去偏转换状态融合方法和基于 MMC 的无偏转换状态融合方法相比, 该方法对于过程噪声和测量噪声的变化不敏感, 比基于 NC 和 MMC 的方法具有更小的位置和速度均方根误差, 即使在大误差的情况下, 仍然具有较高的融合精度和可靠性。

关键词: 数据融合; 分布式 BLUE 滤波; 多雷达; 去偏转换; 无偏转换; 非线性量测

Multi-radar Data Fusion Method Based on Distributed BLUE

FU Ying^{1a,1b,2}, SUN Yong-jian^{1b,3}, TANG Zi-yue^{1b}

(1a. Department of Graduate Management; 1b. Department of Air/Space-Based Early Warning
Surveillance Equipment, Air Force Early Warning Academy, Wuhan 430019, China;
2. PLA 95333 Troops, Changsha 410114, China;
3. Beijing Institute of Radio Measurement, Beijing 100039, China)

【Abstract】 Aiming at the problem of the mixed tracking and fusion problem of linear system and nonlinear observation, a multi-radar data fusion method based on distributed Best Linear Unbiased Estimation(BLUE) filter is provided under the premise that three-dimensional BLUE filter of constant acceleration target motion model is derived. In which, the BLUE target states at cell radar are given in Cartesian coordinates. All the target states estimations are fused at fusion center. The advanced technique is compared with the traditional Nested Conditioning(NC) debiased conversion states fusion method and the Modified Measurement Conditioned(MMC) unbiased conversion states fusion method by taking the position Root-mean-square Error(RMSE), velocity RMSE and Average Normalized Estimation Error Squared(ANEES) as the fusion performance evaluation criterion. Simulation results show that the advanced technique is not sensitive with the variety of the process noise and measurement noise. Its position and velocity RMSE are smaller than the corresponding of NC and MMC based method. It has high fusion accuracy and reliability, even if the errors become larger.

【Key words】 data fusion; distributed Best Linear Unbiased Estimation(BLUE) filtering; multi-radar; debiased conversion; unbiased conversion; nonlinear measurement

DOI: 10.3969/j.issn.1000-3428.2013.04.013

1 概述

现代战争越来越依赖于各作战平台对战场统一态势的共享。将各个传感器对目标的状态估计进行融合处理, 可以获得目标的状态、属性等信息, 为目标识别和分析目标作战意图提供依据。状态融合估计方法主要有基于状态的

融合和基于测量的融合。前者对每个传感器的测量数据进行滤波估计后将其按照最大似然准则融合成最终的状态融合估计, 是一种次优算法, 而后者是一种基于最小均方误差(Minimum Mean Square Error, MMSE)的最优融合算法。从结构上来看, 最优融合(位置融合级系统)算法主要有集中式、分布式、混合式和多级式。集中式结构因数据互联较

作者简介: 付 莹(1982—), 女, 博士研究生, 主研方向: 雷达信号与数据处理, 多传感器数据融合; 孙永健, 讲师、博士研究生; 汤子跃, 教授、博士后

收稿日期: 2012-05-21 **修回日期:** 2012-08-07 **E-mail:** fyradar@126.com

困难, 并且要求系统必须具备大容量的处理能力, 具有计算负担重、系统生存能力差等缺点。混合式体系结构是集中式和分布式两种形式的结合, 这种结构比较复杂一般用于大型融合系统。工程上多采用分布式结构, 即经典的分布式 Kalman 滤波融合算法^[1-3]。

由于目标的动态模型建立在直角坐标系下, 而观测模型建立在球坐标系下, 混合系统的估计问题自然也是非线性的。尽管 Kalman 滤波估计属于最优线性无偏估计范畴, 但只是针对线性系统而言。对于非线性量测, Kalman 滤波并不是最优处理方法。解决这类问题的基本思想是把非线性的量测转化为笛卡儿坐标系下的伪线性量测。因此, 解决球坐标系下量测的目标跟踪问题的一类方法是扩展卡尔曼滤波^[4](Extended Kalman Filter, EKF)和二阶 EKF^[5], 另一类也是最常用的方法, 即量测转换 Kalman 滤波^[6-7], 主要包括嵌套条件(Nested Conditioning, NC)的加性去偏转换 Kalman 滤波^[8]和修正的基于量测(Modified Measurement Conditioned, MMC)的乘性无偏转换 Kalman 滤波^[9]。由于扩展卡尔曼滤波和二阶 EKF 在计算方法上有可能引入了较大的误差, 因此会导致滤波器性能的严重下降。由于量测转换方法产生的误差又依赖于目标的运动状态, 因此估计性能也不是最优的。

文献[10]提出的新型递归 BLUE 滤波器能够处理线性运动模型和非线性量测模型的混合状态估计问题。其在保持极坐标系下量测误差的同时, 对目标在直角坐标系下的状态进行估计。文献[11]给出了基于匀速模型的二维 BLUE 滤波器, 本文在此基础上推导了目标匀加速运动模型下, 基于三维 BLUE 的分布式目标状态融合算法。

2 基于 NC 的加性去偏量测转换状态估计融合

在球坐标系中, 假设目标相对于雷达的真实斜距为 r 、方位角为 θ 、俯仰角为 η , 则雷达量测得到的目标斜距 r_m 、方位角 θ_m 、俯仰角 η_m 可定义为:

$$\begin{cases} r_m = r + \tilde{r} \\ \theta_m = \theta + \tilde{\theta} \\ \eta_m = \eta + \tilde{\eta} \end{cases} \quad (1)$$

其中, 假定斜距测量误差 \tilde{r} ; 方位角测量误差 $\tilde{\theta}$; 俯仰角测量误差 $\tilde{\eta}$ 为相互独立、均值为零的 Gauss 噪声, 标准差分别为 σ_r 、 σ_θ 和 σ_η 。

式(1)表示的球坐标系中的量测可以按式(2)转换成直角坐标系中的量测:

$$\begin{cases} x_m = r_m \cos \eta_m \sin \theta_m \\ y_m = r_m \cos \eta_m \cos \theta_m \\ z_m = r_m \sin \eta_m \end{cases} \quad (2)$$

由于实际中无法得到目标状态真值 (r, θ, φ) , 因此一般采用相对于测量值 $(r_m, \theta_m, \varphi_m)$ 的转换偏差代替相对于目标真实状态的真正偏差:

$$\begin{cases} \mu_a^x = r_m \cos \eta_m \sin \theta_m \left(e^{-\frac{\sigma_r^2}{2}} e^{-\frac{\sigma_\theta^2}{2}} e^{-\frac{\sigma_\eta^2}{2}} \right) \\ \mu_a^y = r_m \cos \eta_m \cos \theta_m \left(e^{-\frac{\sigma_r^2}{2}} e^{-\frac{\sigma_\theta^2}{2}} e^{-\frac{\sigma_\eta^2}{2}} \right) \\ \mu_a^z = r_m \sin \eta_m \left(e^{-\frac{\sigma_r^2}{2}} e^{-\frac{\sigma_\eta^2}{2}} \right) \end{cases} \quad (3)$$

因此, 式(2)的量测转换修正为^[4]:

$$\mathbf{Z}^c = \begin{bmatrix} x_m^c \\ y_m^c \\ z_m^c \end{bmatrix} = \begin{bmatrix} r_m \cos \eta_m \sin \theta_m \\ r_m \cos \eta_m \cos \theta_m \\ r_m \sin \eta_m \end{bmatrix} - \boldsymbol{\mu}_a \quad (4)$$

设目标运动方程为:

$$\mathbf{X}(k) = \boldsymbol{\Phi}(k-1)\mathbf{X}(k-1) + \boldsymbol{\Gamma}(k-1)\mathbf{W}(k-1) \quad (5)$$

去偏转换后的量测方程在直角坐标系下表示为:

$$\mathbf{Z}_i^c(k) = \mathbf{H}_i(k)\mathbf{X}_i(k) + \mathbf{V}_i(k)$$

其中, $i=1, 2, \dots, N$, 表示传感器个数; k 为离散时间变量; $\mathbf{X}(k)$ 为目标状态; $\mathbf{Z}_i^c(k)$ 为第 i 个传感器节点的转换测量值; $\boldsymbol{\Phi}(k)$ 为状态转移矩阵; $\mathbf{H}_i(k)$ 为测量矩阵; $\mathbf{W}(k)$ 和 $\mathbf{V}_i(k)$ 分别为过程噪声和测量噪声向量。

假设 $\mathbf{W}(k)$ 和 $\mathbf{V}_i(k)$ 具有如下的统计特性:

$$(1) E\{\mathbf{W}(k)\mathbf{W}^T(j)\} = \mathbf{Q}(k)\delta_{kj};$$

$$(2) E\{\mathbf{V}_i(k)\mathbf{V}_i^T(j)\} = \mathbf{R}_i(k)\delta_{kj}.$$

$$\text{其中, } \delta_{kj} = \begin{cases} 1 & k=j \\ 0 & k \neq j \end{cases}.$$

可以得到基于 NC 方法的卡尔曼滤波融合算法步骤为:

Step1 根据前一次滤波值 $\hat{\mathbf{X}}_i(k-1)$ (或初值 $\hat{\mathbf{X}}_i(0)$),

计算预测值:

$$\hat{\mathbf{X}}_i(k|k-1) = \boldsymbol{\Phi}(k-1)\hat{\mathbf{X}}_i(k-1) \quad (6)$$

Step2 根据前次得到的滤波误差方差阵 $\mathbf{P}_i(k-1)$ (或初值 $\mathbf{P}_i(0)$), 计算预测误差方差阵:

$$\mathbf{P}_i(k|k-1) = \boldsymbol{\Phi}(k-1)\mathbf{P}_i(k-1)\boldsymbol{\Phi}^T(k-1) + \boldsymbol{\Gamma}(k-1)\mathbf{Q}(k-1)\boldsymbol{\Gamma}^T(k-1) \quad (7)$$

Step3 计算卡尔曼增益:

$$\mathbf{K}_i(k) = \mathbf{P}_i(k|k-1)\mathbf{H}_i^T(k) \left[\mathbf{H}_i(k)\mathbf{P}_i(k|k-1)\mathbf{H}_i^T(k) + \mathbf{R}_i(k) \right]^{-1} \quad (8)$$

Step4 计算滤波估计:

$$\hat{\mathbf{X}}_i(k) = \hat{\mathbf{X}}_i(k|k-1) + \mathbf{K}_i(k) \left[\mathbf{Z}_i^c(k) - \mathbf{H}_i(k)\hat{\mathbf{X}}_i(k|k-1) \right] \quad (9)$$

Step5 计算滤波误差方差阵:

$$\mathbf{P}_i(k) = \left[\mathbf{I} - \mathbf{K}_i(k)\mathbf{H}_i(k) \right] \mathbf{P}_i(k|k-1) \quad (10)$$

Step6 对局部传感器的目标状态估计进行融合得到全局目标状态估计:

$$\begin{aligned}\hat{X}_f(k) &= P_f(k) \sum_{i=1}^N P_i^{-1}(k) \hat{X}_i(k) \\ P_f(k) &= \left[\sum_{i=1}^N P_i^{-1}(k) \right]^{-1}\end{aligned}\quad (11)$$

3 乘性无偏量测转换状态估计融合

虽然传统的乘性无偏量测转换(Measurement Conditioned, MC)方法比 NC 方法具有更好的一致性和鲁棒性, 但其在推导转换量测误差和协方差阵时存在兼容性问题, 即转换量测误差均值直接以目标的状态真值为条件计算, 而转换量测误差协方差阵以目标状态量测值为条件计算。为克服这一不足, 文献[9]提出严格以雷达量测为条件计算无偏转换误差的均值。

$$\begin{cases} \mu_p^x = E[\tilde{x}_m^u | r_m, \theta_m, \eta_m] = \\ \quad (\lambda_\theta^{-1} \lambda_\eta^{-1} - \lambda_\theta \lambda_\eta) r_m \cos \eta_m \sin \theta_m \\ \mu_p^y = E[\tilde{y}_m^u | r_m, \theta_m, \eta_m] = \\ \quad (\lambda_\theta^{-1} \lambda_\eta^{-1} - \lambda_\theta \lambda_\eta) r_m \cos \eta_m \cos \theta_m \\ \mu_p^z = E[\tilde{z}_m^u | r_m, \theta_m, \eta_m] = \\ \quad (\lambda_\eta^{-1} - \lambda_\eta) r_m \sin \eta_m \end{cases}\quad (12)$$

其中:

$$\begin{cases} \lambda_\theta = E[\cos \tilde{\theta}] = e^{-\frac{\sigma_\theta^2}{2}} \\ \lambda_\theta' = E[\cos 2\tilde{\theta}] = e^{-2\sigma_\theta^2} = \lambda_\theta^4 \\ \lambda_\eta = E[\cos \tilde{\eta}] = e^{-\frac{\sigma_\eta^2}{2}} \\ \lambda_\eta' = E[\cos 2\tilde{\eta}] = e^{-2\sigma_\eta^2} = \lambda_\eta^4 \end{cases}$$

无偏量测转换修正为:

$$\mathbf{Z}^u = \begin{bmatrix} x_m^u \\ y_m^u \\ z_m^u \end{bmatrix} = \begin{bmatrix} r_m \cos \eta_m \sin \theta_m \\ r_m \cos \eta_m \cos \theta_m \\ r_m \sin \eta_m \end{bmatrix} - \boldsymbol{\mu}_p \quad (13)$$

基于 MMC 的卡尔曼滤波融合算法步骤除量测转换外, 其他步骤与基于 NC 的卡尔曼滤波融合算法步骤相同。

4 基于分布式 BLUE 滤波的状态估计融合

由前文可知, 量测转换方法的转换量测误差依赖于目标的运动状态, 其协方差阵是以当前时刻雷达的量测或目标运动状态和雷达在当前时刻的量测为条件来估计的; 另外, 在标准的 Kalman 滤波中, 要求量测噪声与目标运动状态独立, 量测噪声的协方差阵是无条件的并且量测噪声是白噪声, 但转换量测误差序列不是白化的。因此, 基于量

测转换的 Kalman 滤波方法对目标运动状态的估计不是最优的, 必将导致目标状态融合精度下降。

理论上最优线性无偏估计器(BLUE)只需满足观测值是估计值的线性函数的条件, 并未要求量测模型是线性的, 它在量测模型非线性的情况下仍是最优的。该滤波器可以很好地解决包括线性运动模型和非线性量测模型的混合系统估计问题。其基本思想是在保持极坐标系下的量测误差的同时, 直接去表达直角坐标系下的状态估计^[10]。这不仅克服了量测转换方法的缺陷, 而且在估计误差和滤波器的可靠性方面都明显超过了量测转换方法, 有利于提高目标状态的融合精度。

将雷达在球坐标中的量测转换到直角坐标系中, 可以得到:

$$x_m = (r + \tilde{r}) \cos(\eta + \tilde{\eta}) \sin(\theta + \tilde{\theta}) \quad (14)$$

$$y_m = (r + \tilde{r}) \cos(\eta + \tilde{\eta}) \cos(\theta + \tilde{\theta}) \quad (15)$$

$$z_m = (r + \tilde{r}) \sin(\eta + \tilde{\eta}) \quad (16)$$

这样雷达在球坐标系中的量测可以表示为:

$$\mathbf{Z}(k) = h(\mathbf{X}(k), \mathbf{V}(k)) \quad (17)$$

其中, $\mathbf{X}(k) = [x, \dot{x}, \ddot{x}, y, \dot{y}, \ddot{y}, z, \dot{z}, \ddot{z}]_k^T$; $\mathbf{Z}(k) = [x_m, y_m, z_m]_k^T$; $\mathbf{V}(k) = [\tilde{r}, \tilde{\theta}, \tilde{\eta}]_k^T$ 。

对于式(5)的目标运动方程和式(17)所示的雷达测量方程, 如果已知目标在 $k-1$ 时刻状态的最优线性无偏估计器估计为 $\hat{\mathbf{X}}(k-1)$, 相应的协方差矩阵为 $\mathbf{P}(k-1)$, 那么目标在 k 时刻的运动状态可用以下递推 BLUE 滤波进行最优估计:

$$\begin{cases} \bar{\mathbf{X}}(k) = \boldsymbol{\Phi}(k-1) \hat{\mathbf{X}}(k-1) + \boldsymbol{\Gamma}(k-1) \bar{\mathbf{W}}(k-1) \\ \tilde{\mathbf{X}}(k) = \mathbf{X}(k) - \bar{\mathbf{X}}(k) \\ \bar{\mathbf{P}}(k) = \boldsymbol{\Phi}(k-1) \mathbf{P}(k-1) \boldsymbol{\Phi}^T(k-1) + \\ \quad \boldsymbol{\Gamma}(k-1) \mathbf{Q}(k-1) \boldsymbol{\Gamma}^T(k-1) \end{cases}\quad (18)$$

$$\begin{cases} \bar{\mathbf{Z}}(k) = E^*[\mathbf{Z}(k) | \mathbf{Z}(k-1)] \\ \tilde{\mathbf{Z}}(k) = \mathbf{Z}(k) - \bar{\mathbf{Z}}(k) \\ \mathbf{S}(k) = \text{cov}[\tilde{\mathbf{Z}}(k)] \\ \mathbf{K}(k) = \text{cov}[\tilde{\mathbf{X}}(k), \tilde{\mathbf{Z}}(k)] \mathbf{S}^{-1}(k) \end{cases}\quad (19)$$

$$\begin{cases} \hat{\mathbf{X}}(k) = \bar{\mathbf{X}}(k) + \mathbf{K}(k) \tilde{\mathbf{Z}}(k) \\ \tilde{\mathbf{X}}(k) = \mathbf{X}(k) - \hat{\mathbf{X}}(k) \\ \mathbf{P}(k) = \bar{\mathbf{P}}(k) - \mathbf{K}(k) \mathbf{S}(k) \mathbf{K}^T(k) \end{cases}\quad (20)$$

其中, $E^*[\cdot]$ 表示 BLUE 估计。可以看出, 只要计算出 $\bar{\mathbf{Z}}(k)$ 、 $\mathbf{S}(k)$ 和 $\text{cov}[\tilde{\mathbf{X}}(k), \tilde{\mathbf{Z}}(k)]$, 就可以最优地估计目标在 k 时刻的运动状态。

假定 $\tilde{r}, \tilde{\theta}, \tilde{\eta}$ 均服从 Gauss 分布, 可得:

$$\begin{cases} \lambda_1 = E(\cos \tilde{\theta}) = e^{-\sigma_{\tilde{\theta}}^2/2} \\ \lambda_2 = E(\cos^2 \tilde{\theta}) = (1 + e^{-2\sigma_{\tilde{\theta}}^2})/2 \\ \lambda_3 = E(\sin^2 \tilde{\theta}) = (1 - e^{-2\sigma_{\tilde{\theta}}^2})/2 \\ \mu_1 = E(\cos \tilde{\eta}) = e^{-\sigma_{\tilde{\eta}}^2/2} \\ \mu_2 = E(\cos^2 \tilde{\eta}) = (1 + e^{-2\sigma_{\tilde{\eta}}^2})/2 \\ \mu_3 = E(\sin^2 \tilde{\eta}) = (1 - e^{-2\sigma_{\tilde{\eta}}^2})/2 \\ E(\sin \tilde{\theta} \cos \tilde{\theta}) = E(\sin \tilde{\theta}) = 0 \\ E(\sin \tilde{\eta} \cos \tilde{\eta}) = E(\sin \tilde{\eta}) = 0 \end{cases} \quad (21)$$

由于 (r, θ, η) 与 $(\tilde{r}, \tilde{\theta}, \tilde{\eta})$ 相互独立, 因此 (x, y, z) 与 $(\tilde{x}, \tilde{y}, \tilde{z})$ 也是相互独立的。又由于 $V(k)$ 是白噪声序列, 则 $E[V(k)|Z(k-1)] = E[V(k-1)] = 0$, 因此可得 $Z(k)$ 的一步预测为:

$$\bar{Z}(k) = [\lambda_1 \mu_1 \bar{x}, \lambda_1 \mu_1 \bar{y}, \lambda_1 \mu_1 \bar{z}]^T = [\lambda_1 \mu_1 \bar{X}_k(1,1), \lambda_1 \mu_1 \bar{X}_k(4,1), \lambda_1 \mu_1 \bar{X}_k(7,1)]^T \quad (22)$$

其中, $\bar{X}_k(i,1)$, $i=1,4,7$ 表示位于 $\bar{X}(k)$ 第 i 行第 1 列的元素。

$$\begin{aligned} \text{cov}(\tilde{X}(k), \tilde{Z}(k)) &= E[X(k)Z^T(k)] - E[\bar{X}(k)\bar{Z}^T(k)] = \\ &= \begin{bmatrix} \lambda_1 \mu_1 \bar{P}_k(1,1) & \lambda_1 \mu_1 \bar{P}_k(1,4) & \mu_1 \bar{P}_k(1,7) \\ \lambda_1 \mu_1 \bar{P}_k(2,1) & \lambda_1 \mu_1 \bar{P}_k(2,4) & \mu_1 \bar{P}_k(2,7) \\ \lambda_1 \mu_1 \bar{P}_k(3,1) & \lambda_1 \mu_1 \bar{P}_k(3,4) & \mu_1 \bar{P}_k(3,7) \\ \lambda_1 \mu_1 \bar{P}_k(4,1) & \lambda_1 \mu_1 \bar{P}_k(4,4) & \mu_1 \bar{P}_k(4,7) \\ \lambda_1 \mu_1 \bar{P}_k(5,1) & \lambda_1 \mu_1 \bar{P}_k(5,4) & \mu_1 \bar{P}_k(5,7) \\ \lambda_1 \mu_1 \bar{P}_k(6,1) & \lambda_1 \mu_1 \bar{P}_k(6,4) & \mu_1 \bar{P}_k(6,7) \\ \lambda_1 \mu_1 \bar{P}_k(7,1) & \lambda_1 \mu_1 \bar{P}_k(7,4) & \mu_1 \bar{P}_k(7,7) \\ \lambda_1 \mu_1 \bar{P}_k(8,1) & \lambda_1 \mu_1 \bar{P}_k(8,4) & \mu_1 \bar{P}_k(8,7) \\ \lambda_1 \mu_1 \bar{P}_k(9,1) & \lambda_1 \mu_1 \bar{P}_k(9,4) & \mu_1 \bar{P}_k(9,7) \end{bmatrix} = \\ &= \mu_1 [\lambda_1 \bar{P}_k(:,1), \lambda_1 \bar{P}_k(:,3), \bar{P}_k(:,7)] \end{aligned} \quad (23)$$

其中, $\bar{P}_k(i,j)$, $i=1,2,\dots,9$, $j=1,4,7$ 表示位于 $\bar{P}(k)$ 第 i 行第 j 列的元素。而 $\bar{P}_k(:,j)$, $j=1,4,7$ 则表示 $\bar{P}(k)$ 的第 j 列。

$$S(k) = E[Z(k)Z^T(k)] - E[\bar{Z}(k)\bar{Z}^T(k)] = \begin{bmatrix} s_{11} & s_{12} & s_{13} \\ s_{21} & s_{22} & s_{23} \\ s_{31} & s_{32} & s_{33} \end{bmatrix} \quad (24)$$

其中:

$$\begin{aligned} s_{11} &\approx \lambda_2 \mu_2 \bar{P}(1,1) + \lambda_3 \mu_2 \bar{P}(4,4) + \alpha(\lambda_2 \bar{x}^2 + \lambda_3 \bar{y}^2) + \alpha_1 \\ s_{22} &\approx \lambda_2 \mu_2 \bar{P}(4,4) + \lambda_3 \mu_2 \bar{P}(1,1) + \alpha(\lambda_3 \bar{x}^2 + \lambda_2 \bar{y}^2) + \alpha_2 \end{aligned}$$

$$\begin{aligned} s_{33} &\approx \mu_2 \bar{P}(7,7) + \\ &\mu_3 \left(\bar{P}(1,1) + \bar{P}(4,4) + \mu_2 \sigma_r^2 \frac{\bar{z}^2}{\bar{r}^2} + \mu_3 \sigma_r^2 \frac{\bar{r}_1^2}{\bar{r}^2} \right) + \alpha_3 \\ s_{12} &= s_{21} \approx (\lambda_2 - \lambda_3)(\mu_2 \bar{P}(1,4) + \alpha \bar{x} \bar{y}) + \alpha_4 \\ s_{13} &= s_{31} \approx \lambda_1 (\mu_2 - \mu_3) \left(\bar{P}(1,7) + \sigma_r^2 \frac{\bar{x} \bar{z}}{\bar{r}^2} \right) + \alpha_5 \bar{x} \\ s_{23} &= s_{32} \approx \lambda_1 (\mu_2 - \mu_3) \left(\bar{P}(4,7) + \sigma_r^2 \frac{\bar{y} \bar{z}}{\bar{r}^2} \right) + \alpha_5 \bar{y} \\ \begin{cases} \bar{r} = \sqrt{\bar{x}^2 + \bar{y}^2 + \bar{z}^2}, \bar{r}_1 = \sqrt{\bar{x}^2 + \bar{y}^2} \\ \alpha = \frac{\mu_2 \sigma_r^2}{\bar{r}^2} + \frac{\mu_3 \bar{z}^2}{\bar{r}_1^2} + \frac{\mu_3 \sigma_r^2 \bar{z}^2}{\bar{r}^2 \bar{r}_1^2} \\ \alpha_1 = (\lambda_2 \mu_2 - \lambda_1^2 \mu_1^2) \bar{x}^2 + \lambda_3 \mu_2 \bar{y}^2 \\ \alpha_2 = (\lambda_2 \mu_2 - \lambda_1^2 \mu_1^2) \bar{y}^2 + \lambda_3 \mu_2 \bar{x}^2 \\ \alpha_3 = (\mu_2 - \mu_1^2) \bar{z}^2 + \mu_3 (\bar{x}^2 + \bar{y}^2) \\ \alpha_4 = (\mu_2 (\lambda_2 - \lambda_3) - \lambda_1^2 \mu_1^2) \bar{x} \bar{y} \\ \alpha_5 = (\lambda_1 (\mu_2 - \mu_3) - \lambda_1 \mu_1^2) \bar{z} \end{cases} \end{aligned}$$

可以得到基于分布式 BLUE 滤波的状态融合步骤为:

Step1 预测:

$$\bar{X}_i(k) = \Phi(k-1) \hat{X}_i(k-1) + \Gamma(k-1) \bar{W}(k-1) \quad (25)$$

$$\begin{aligned} \bar{P}_i(k) &= \Phi(k-1) P_i(k-1) \Phi^T(k-1) + \\ &\Gamma(k-1) Q(k-1) \Gamma^T(k-1) \end{aligned} \quad (26)$$

其中, $i=1,2,\dots,N$, 表示传感器个数。

Step2 计算滤波增益:

$$K_i(k) = \mu_1 [\lambda_1 \bar{P}_{ik}(:,1), \lambda_1 \bar{P}_{ik}(:,4), \bar{P}_{ik}(:,7)] S_i^{-1}(k) \quad (27)$$

Step3 计算各局部传感器的滤波估计:

$$\begin{aligned} \hat{X}_i(k) &= \bar{X}_i(k) + K_i(k) \{Z_i(k) - \mu_1 [\lambda_1 \bar{x}, \lambda_1 \bar{y}, \bar{z}]^T\} \\ P_i(k) &= \bar{P}_i(k) - K_i(k) S_i(k) K_i^T(k) \end{aligned} \quad (28)$$

Step4 利用式(11)对局部传感器的目标状态估计进行融合得到全局目标状态估计。

5 性能评价与仿真分析

5.1 融合性能评价标准

为了真实地反映出融合后的效果, 本文采用 Monte-Carlo 多次实验的方法, 与基于 NC 和 MMC 的融合算法进行比较研究。并采用位置、速度均方根误差(RMSE)和平均归一化估计误差平方(ANEES)作为融合性能评价标准。其中平均归一化估计误差平方无量纲, 定义为:

$$A_{\text{ANEES}} = \frac{1}{Nn} \sum_{i=1}^N (X_i - \hat{X}_i)^T P_i^{-1} (X_i - \hat{X}_i) \quad (29)$$

其中, $(x_i - \hat{x}_i)$ 和 P_i 为第 i 次循环的估计误差和误差协方差阵; n 为状态向量维数; N 为 Monte Carlo 仿真次数。状态

估计误差与误差协方差阵越匹配,即越接近 1,则融合算法可靠性和置信度越高。

5.2 仿真分析

假设有 2 部雷达对同一个目标进行观测。雷达系统参数如表 1 所示。

表 1 雷达系统参数					
雷达	飞行速度/(m·s ⁻¹)	飞行高度/m	起始位置/m	观测时间/s	采样周期/s
雷达 1	180	8 000	(0,0)	500	1
雷达 2	200	10 000	(80 000,0)	500	1

设目标运动模型为 CA 模型,即有:

$$X(k)=[x_k \quad \dot{x}_k \quad \ddot{x}_k \quad y_k \quad \dot{y}_k \quad \ddot{y}_k \quad z_k \quad \dot{z}_k \quad \ddot{z}_k]^T$$
$$F_1=\begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, G_1=\begin{bmatrix} T^3/6 \\ T^2/2 \\ T \end{bmatrix}$$
$$F(k)=\text{diag}(F_1, F_1, F_1), G=\text{diag}(G_1, G_1, G_1)$$

情况 1 过程噪声方差阵 $Q=\text{diag}(10,10,10^{-2})$, 量测误差 $\sigma_{r1}=\sigma_{r2}=5\text{ m}$, $\sigma_{\theta1}=\sigma_{\theta2}=4\text{ mrad}$, $\sigma_{\eta1}=\sigma_{\eta2}=4\text{ mrad}$, Monte Carlo 次数为 100。由图 1~图 3 可以看出,在测量噪声方差较小的情况下,3 种方法的位置和速度均方误差相差不大,都具有较高的融合精度;基于分布式 BLUE 滤波的融合方法的 ANEES 经过暂态过程后最接近 1,因此估计误差与估计协方差的匹配较好,较其他 2 种方法而言具有高置信度和可靠性。同时可以看出,基于 NC 的方法比基于 MMC 的融合方法具有更高的可靠性,但是基于 MMC 的方法比基于 NC 的方法融合精度高。




图 1 位置 RMSE 随时间变化曲线(情况 1)




图 2 速度 RMSE 随时间变化曲线(情况 1)




图 3 ANEES 随时间变化曲线(情况 1)

情况 2 过程噪声方差阵 $Q=\text{diag}(10,10,10^{-2})$, 量测误差 $\sigma_{r1}=5\text{ m}$, $\sigma_{r2}=50\text{ m}$, $\sigma_{\theta1}=4\text{ mrad}$, $\sigma_{\theta2}=100\text{ mrad}$, $\sigma_{\eta1}=4\text{ mrad}$, $\sigma_{\eta2}=100\text{ mrad}$, Monte Carlo 次数为 100。在过程噪声参数不变的情况下,增大了其中一部雷达的测量噪声。由图 3~图 6 可以看出,3 种方法的位置和速度均方误差都有所增大,融合精度有所下降。但比较而言,基于分布式 BLUE 滤波的融合方法仍然具有较小的位置和速度均方误差、较高的融合精度和可靠性。




图 4 位置 RMSE 随时间变化曲线(情况 2)




图 5 速度 RMSE 随时间变化曲线(情况 2)




图 6 ANEES 随时间变化曲线(情况 2)

情况 3 过程噪声方差阵 $Q = \text{diag}(10^2, 10^2, 10^{-2})$, 量测误差 $\sigma_{r1} = 50 \text{ m}$, $\sigma_{r2} = 50 \text{ m}$, $\sigma_{\theta1} = 100 \text{ mrad}$, $\sigma_{\theta2} = 100 \text{ mrad}$, $\sigma_{\eta1} = 100 \text{ mrad}$, $\sigma_{\eta2} = 100 \text{ mrad}$, Monte Carlo 次数为 100。如图 7~图 9 所示, 在过程噪声参数增大和 2 部雷达的测量噪声都增大的情况下, 基于 MMC 的融合方法的位置均方误差明显发散。基于分布式 BLUE 滤波的融合算法较 MMC 和 NC 算法而言, 仍然具有更小的位置和速度均方根误差和高可靠性。




图 7 位置 RMSE 随时间变化曲线(情况 3)




图 8 速度 RMSE 随时间变化曲线(情况 3)




图 9 ANEES 随时间变化曲线(情况 3)

6 结束语

在目标线性动态模型和观测高度非线性的情况下, 传统的基于量测转换的跟踪方法必然会带来较大的转换误差, 从而降低多雷达联合跟踪时的融合精度, 甚至出现发散的情况。最佳线性无偏估计能够实现对非线性观测的最佳滤波, 解决了转换误差问题。因此, 本文在推导目标匀加速运动时的三维 BLUE 滤波器的基础上, 提出了基于分

布式 BLUE 滤波的多雷达目标状态估计融合方法。通过与经典的基于 NC 和 MMC 的融合方法进行仿真比较, 可以得出以下结论: 基于分布式 BLUE 滤波器的融合算法的估计误差和估计协方差的匹配性好, 对过程噪声和测量噪声的变化不敏感。即使在过程噪声和测量噪声都很强的环境中, 基于分布式 BLUE 滤波器的融合算法仍具有较高的融合精度和可靠性, 具有明显的优越性和一定的工程参考价值。本文主要研究目标动态模型为线性的情况, 下一步将对目标非线性动态模型条件下基于分布式 BLUE 滤波的多雷达融合跟踪问题进行深入研究。

参考文献

- [1] 王思文. 两种异步多传感器数据融合算法的比较[J]. 制造业自动化, 2011, 33(9): 68-70.
- [2] 尚晓星, 李俊霞. 基于不敏 Kalman 滤波的多传感器数据融合算法[J]. 河南师范大学学报: 自然科学版, 2011, 39(4): 66-69.
- [3] 黄桃, 张天哄, 李越雷, 等. 分布式多传感器融合跟踪[J]. 火力与指挥控制, 2011, 36(6): 9-12.
- [4] 潘丽娜. 基于扩展卡尔曼滤波的多传感器目标跟踪[J]. 舰船电子工程, 2010, 30(12): 71-72.
- [5] 冯道旺, 李腾, 黄知涛. 平方根二阶 EKF 及其在目标运动分析中的应用[J]. 系统工程与电子技术, 2009, 31(9): 2101-2105.
- [6] 李莉, 宋志强. 转换坐标卡尔曼滤波算法在雷达数据融合中的应用[J]. 仪器仪表用户, 2011, 18(4): 81-82.
- [7] 王宝宝, 吴盘龙, 杨宝建, 等. 去偏转换量测 Kalman 滤波器的 FPGA 实现[J]. 电光与控制, 2011, 18(9): 73-77.
- [8] Lerro D, Bar-Shalom Y. Tracking with Debiased Consistent Converted Measurements Versus EKF[J]. IEEE Transactions on Aerospace and Electronic Systems, 1993, 29(3): 1015-1022.
- [9] Duan Zhansheng, Han Chongzhao, Li Xiaorong. Comments on Unbiased Converted Measurements for Tracking[J]. IEEE Transactions on Aerospace and Electronic Systems, 2004, 40(4): 1374-1377.
- [10] Zhao Zhanlue, Li Xiaorong, Jilkov V P, et al. Optimal Linear Unbiased Filtering with Polar Measurements for Target Tracking[C]//Proc. of the 5th FUSION'02. [S. l.]: IEEE Press, 2002: 1527-1534.
- [11] 韩崇昭, 朱洪艳, 段战胜. 多源信息融合[J]. 北京: 清华大学出版社, 2010.

编辑 索书志

