

一种实现机动目标跟踪的 STF 动态模型 PDA 算法

徐 毓¹, 杨瑞娟², 周 焰²

(1. 清华大学自动化系, 北京 100084; 2. 空军雷达学院, 湖北武汉 430010)

摘 要: 本文提出了一种基于强跟踪滤波器(STF)的模型结构动态调整的概率数据关联算法(STF-PDA). 该算法提高了概率数据关联(PDA)算法的性能. 在跟踪目标, 尤其是在跟踪机动目标的性能上, 理论分析表明该算法比基于KF或EKF的PDA方法优越. 且与基于KF和EKF的PDA算法进行了实验结果比较, 结果表明, 本文提出的算法更为有效.

关键词: 目标跟踪; 强跟踪滤波器; 概率数据关联

中图分类号: TN911. 2 **文献标识码:** A **文章编号:** 0372-2112 (2003) 07-0981-04

An Algorithm STF-PDA for Maneuvering Target Tracking with Dynamic Model

XU Yu¹, YANG Rui-juan², ZHOU Yan²

(1. Dept of Automation, Tsinghua University, Beijing 100084, China; 2. Radar Academy of Air Force, Wuhan, Hubei 430010, China)

Abstract: An algorithm STF-PDA has been presented based on the strong tracking filter with dynamically modifying structure of model. The performance of probability data association (PDA) can be improved by this algorithm. The theoretic analysis shows the algorithm is superior to the PDA with Kalman or extended Kalman filter. Compared with the latter one on simulations the simulations show that this new algorithm is more effective.

Key words: target tracking; strong tracking filter; probability data association

1 引言

杂波环境下数据关联问题一直是雷达数据处理领域被广泛研究的问题, 各种算法不断出现^[2~4]. 这个问题在空中交通管制、安全监视、机器人视觉等领域同样会遇到. 数据关联的目的是要将来自多个传感器的观测数据动态地合理地与目标航迹关联起来, 区分哪些观测数据来自同一目标. 一旦形成航迹并且被确认, 就可以估计目标的数目和参数. 比如目标的位置、速度等.

跟踪问题通常由三部分组成: 航迹起始、航迹维持和航迹删除. 不管在哪一部分, 都要涉及观测与航迹关联这一关键问题. 到目前为止, 已有许多文献对这一问题进行了讨论, 提出了各种算法, 如 NN、GNN、PDA 和扩展到多目标环境下的 JPDA 等^[5,6]. 基于上述数据关联方法, 提出了多目标跟踪方法, 如 KF、EKF、IMM 和 MTH 等^[7,8]. 在这些数据关联和目标跟踪的方法中, 大都是建立在 Kalman 滤波器或扩展的 Kalman 滤波器理论上. 但 Kalman 和扩展 Kalman 滤波器存在一些不足^[11]: 对模型参数不确定性的鲁棒性较差; 当系统达到稳态时, 其增益趋于极值, 此时将丧失对突变状态的跟踪能力; 对初始值的依赖性较大. 而强跟踪滤波器^[1] (Strong Tracking Fil-

ter, STF) 针对上述问题通过引进渐消因子, 迫使输出残差近似正交, 可以看成是一种自适应的非线性滤波器. 用于状态与参数的联合估计时, 能够取代 KF 和 EKF.

数据关联过程中所采用的目标运动描述模型是影响 PDA 算法性能好坏的一个重要因素. 由于目标运动的特性是未知的, 因此, 无论如何选择模型, 总是存在模型的不确定性. 在以往的 PDA 算法中, 大都是采用不变结构的目标运动模型, 这样由于模型与目标实际运动特性之间的差异, 导致估计和跟踪产生误差. 本文以强跟踪滤波器理论为基础, 提出了一种新的可适用于杂波环境的动态调整模型结构的数据关联 STF-PDA 方法. 在算法中, 通过在描述目标运动的状态方程中引入调节因子, 调节因子随输出残差而改变模型结构, 调节系统噪声水平, 使之减小模型的不确定性, 从而提高估计和跟踪精度.

2 强跟踪滤波器与目标模型

我们知道, 目标运动的机动性主要体现在状态方程中的随机项, Singer 模型假设加速度为一阶马尔可夫过程. 白噪声模型则假定加速度为白噪声. 实际上, 目标机动可能是由多种因素引起的, 本文引入一个调节因子 (k) , 即下面所说的渐

消因子,根据模型输出误差实时调节描述目标运动特性,当目标发生机动时,增大当前 Kalman 滤波器误差方差矩阵,从而增大当前增益;增大过程噪声方差矩阵或自适应地在不同水平上选择过程噪声方差;以减小模型的不确定性.即设目标的运动特性由下面可变状态方程描述:

$$\begin{cases} X(k+1) = f(k, X(k)) + d(k) v(k) \\ Z(k+1) = h(k+1, X(k+1)) + w(k) \end{cases} \quad (1)$$

其中, $X(k)$ 是目标 k 时刻的运动状态向量, $Z(k)$ 是对目标 k 时刻的观测向量, $d(k)$ 是模型系统噪声水平调节因子,在下一节给出; $v(k)$, $w(k)$ 是零均值的高斯白噪声,且具有如下的统计特性:

$$E[v(k)] = E[w(k)] = \mathbf{0}; E[v(k) v^T(j)] = Q(k) \delta_{k,j};$$

$$E[w(k) w^T(j)] = R(k) \delta_{k,j}; E[v(k) w^T(j)] = \mathbf{0}$$

对于式(1)的状态估计问题,当 f 和 h 是线性函数时,可以使用 Kalman 滤波器解决;当 f 和 h 是非线性函数时,多采用扩展 Kalman 滤波器(EKF)技术.前者很难适用于机动目标跟踪,后者则在模型具有不确定性时,其鲁棒性有时较差,造成状态估计精度不高,甚至有时出现发散现象.此外,当系统达到平稳状态后,目标状态突然变化发生时,EKF 和 KF 可能丧失对突变状态的跟踪能力,但这种机动目标跟踪性能(尤其是在目标进入空战区域)是十分重要的.各种数据关联算法,如 PDA,JPDA,GNN 及在这些基础上改进的一些算法都是以 KF 和 EKF 滤波强跟踪滤波器为基础的,用 KF 或 EKF 的方法计算增益,由此实质上涉及计算状态波门中的统计距离和测量与航迹的关联概率.因此,当增益丧失跟踪能力时,上述算法也就随之产生过大的误差.为了较好地跟踪机动目标,Blom 提出了多模型算法(MMF)^[7],即采用多个模型同时跟踪.在此基础上,Bar-Shalom 和 Blom 联合提出了相互作用多模型概率数据关联算法(IMMPDAF)^[8].从而提高了机动目标跟踪的性能,但同时计算量也有所增加,模型的选择也要求根据实际情况决定.而强跟踪滤波器使用正交性原理,引进时变的渐消因子 $\lambda(k)$,使滤波器关于模型的不确定性保持较好的鲁棒性.通过实时调节增益,促使测量残差近似正交,从而提高跟踪性能.

如果 f 和 h 是非线性函数,则在预测点进行线性化处理,测量矩阵和状态转移矩阵分别取一阶导数矩阵:

$$\begin{cases} H(k+1, X(k+1|k)) = \frac{\partial h(k+1, X(k+1))}{\partial X} \Big|_{X(k+1) = X(k+1|k)} \\ F(k, X(k|k)) = \frac{\partial f(k, X(k))}{\partial X} \Big|_{X(k) = X(k|k)} \end{cases}$$

进行 Kalman 滤波时,式(1)的状态估计算法的增益和残差计算公式为:

$$\begin{aligned} K(k+1) &= P(k+1|k) H^T(k+1, X(k+1|k)) [H(k+1, \\ & X(k+1|k)) P(k+1|k) H^T(k+1, \\ & X(k+1|k)) + R(k+1)]^{-1} \\ X(k+1) &= Z(k+1) - h(k+1, X(k+1|k)) \end{aligned}$$

当系统达到稳态并且 KF(EKF) 也达到稳态时,其预报误差协方差 $P(k+1|k)$ 将趋于极小值^[9],导致 $K(k+1)$ 也趋于极小值.此时,当状态 $X(k+1)$ 发生突变时,就会导致残差增

大,但 $P(k+1|k)$ 和 $K(k+1)$ 并不能随之增大,从而 KF(EKF) 基本丧失对突变状态的跟踪能力.强跟踪滤波器(STF)采用在线选择适当的时变增益 $K(k+1)$,使得

$$E\{ [X(k+1) - X(k+1|k+1)] [X(k+1) - X(k+1|k+1)]^T \} = \min$$

$$E\{ \lambda(k+1+j) \lambda^T(k+1) \} = 0, k=0, 1, \dots, j=1, 2, \dots$$

条件()是 Kalman 滤波器的性能指标.条件()要求不同时刻的残差序列处处保持正交.已经证明,当模型与实际系统完全匹配时,KF 滤波器的输出残差序列是不自相关的高斯白噪声序列^[10],()满足这一要求,因而不减弱 KF 的性能.但在实际问题中,选择的模型不可避免地存在不确定性,因此 KF 的输出残差不可能白化.建立在性能指标()和()基础上的强跟踪滤波器(STF),通过引进渐消因子 $\lambda(k)$,实时调节增益 $K(k)$,强迫输出残差近似为高斯白噪声,最大程度地提取输出残差中一切有效信息,从而提高对机动目标的跟踪能力.

对模型式(1),次优渐消因子可以由下式计算^[11]:

$$\lambda(k+1) = \begin{cases} 0, & 0 < 1 \\ 1, & 0 < 1 \end{cases} \quad (2)$$

其中:

$$\lambda = \frac{\text{tr}[N(k+1)]}{\text{tr}[M(k+1)]}$$

$$N(k+1) = S(k+1) - H(k+1, X(k+1|k)) P(k+1|k) Q(k) Q^T(k) H^T(k+1, X(k+1|k)) - R(k+1) \quad (3)$$

$$M(k+1) = H(k+1, X(k+1|k)) F(k, X(k|k)) P(k|k) F^T(k, X(k|k)) H^T(k+1, X(k+1|k))$$

$S(k+1)$ 是残差方差矩阵

$$S(k+1) = \begin{cases} (1) \lambda^T(1), & k=0 \\ \frac{S(k) + \lambda(k+1) \lambda^T(k+1)}{1 + \lambda(k+1)}, & k \geq 1 \end{cases} \quad (4)$$

$0 < \lambda < 1$ 为遗忘因子,一般取 $\lambda = 0.95$.式(3)中的弱化因子 λ 是为了使状态估计值更加平滑,可凭经验选定.

定义模型系统噪声水平调节因子

$$d(k) = \begin{cases} d(k-1), & (k) = 1 \\ \lambda(k) (k-1) / d(k-1), & (k) > 1 \end{cases}$$

初始值取 $d(0) = 1$, $d(1) = 1$.容易看出,当 $\lambda(k)$ 增大时, $d(k)$ 也增大,反之亦然;当 $\lambda(k) = 1$ 时,有 $d(k) = 1$,此时强跟踪滤波器就转变成 Kalman 滤波器了.

基于模型调节因子的强跟踪滤波器对式(1)的状态估计方法为:

$$X(k+1|k+1) = X(k+1|k) + K(k+1) (Z(k+1) - h(k+1, X(k+1|k)))$$

预报误差协方差为:

$$P(k+1|k) = (k+1) [F(k, X(k|k)) P(k|k) F^T(k, X(k|k)) + d(k) (k) Q(k) Q^T(k)]$$

增益为:

$$\begin{aligned} K(k+1) &= P(k+1|k) H^T(k+1, X(k+1|k)) [H(k+1, \\ & X(k+1|k)) P(k+1|k) H^T(k+1, \\ & X(k+1|k)) + R(k+1)]^{-1} \end{aligned}$$

3 STF-PDA 算法

假设在航迹 i 的波门内有 N 个观测,包括真目标观测、假目标观测和杂波等,据此可对航迹 i 建立 $N+1$ 个假设: $H_j, j=0, 1, 2, \dots, N$. 其中,

H_0 : N 个观测中没有一个是有效的;

$H_j(j=0)$: 观测 j 是有效的.

假设 P_D 为检测概率, P_G 为真目标观测落在波门内的概率(一般有 $P_G > 1$),可得各假设的概率为^[3]:

$$p_{i0} = (1 - P_D P_G)^N,$$

$$p_{ij} = (1 - P_D P_G)^{N-1} P_D P_G \frac{e^{-d_{ij}^2/2}}{P_G(2)^{M/2} \sqrt{|S_{ij}|}} = \frac{N-1}{(2)^{M/2} \sqrt{|S_{ij}|}} P_D \exp(-d_{ij}^2/2)$$

归一化处理得到

$$p_{ij} = \begin{cases} \frac{b}{N}, & j=0 \\ b + \frac{ij}{k=0}, & 1 \leq j \leq N \end{cases} \quad (5)$$

其中, $b = (1 - P_D P_G) (2)^{M/2} \sqrt{|S_{ij}|}$, $ij = P_D \exp(-d_{ij}^2/2)$, $= N/V_G, V_G$ 是波门体积^[3].

记 $i_j(k)$ 为观测 j 相应于航迹 i 的残差,则在 k 时刻,统计距离形式上没有改变,但是基于式(4)计算

$$d_{ij}^2 = i_j(k) S_{ij}^{-1}(k) i_j^T(k)$$

概率数据关联的思想就是利用上述概率对假设合并,根据强跟踪滤波器计算,可得到相应于观测 j 的残差

$$i_j(k) Z_j(k) - h(k, X_i(k|k-1)) \quad (6)$$

对各残差以 p_{ij} 为权进行组合: $i(k) = \sum_{j=1}^N p_{ij} i_j(k)$

状态估计的组成为: $X_i(k|k) = \sum_{j=1}^N p_{ij} X_{ij}(k|k)$

目标状态更新协方差矩阵为

$$\begin{cases} P(k|k) = P^0(k|k) + dP(k) \\ P^0(k|k) = p_{i0} P(k|k-1) + (1 - p_{i0}) P^c(k|k) \\ P^c(k|k) = P(k|k-1) - K(k) S(k) K^T(k) \end{cases} \quad (7)$$

$$dP(k) = K^Q(k) \left[\sum_{j=1}^N p_{ij} i_j^T i_j - \sum_{ij} i_{ij}^T i_{ij} \right] K^{QT}(k)$$

其中, $P^0(k|k)$ 表示单个观测存在且是正确的关联的强滤波方差矩阵.

从上面可以看出,当目标状态发生突变,即机动时,残差 $i(k)$ 将会突然增大,从而引起渐消因子 $i(k)$ 的适当增加,导致了一步预测方差矩阵的增大,进而导致增益矩阵增大.也就提高了对目标状态估计的补偿能力,保证了对突变状态的跟踪能力.对数据关联而言,关联概率与统计距离密切相关,而统计距离则随状态估计是否准确变化.只有状态估计准确,其波门路径才能始终沿着目标航迹移动,并不因为状态突变而导致波门突然变大,从而失去关联能力.

4 仿真结果分析

例 1 为简便起见,不考虑目标的高度,位置采样周期为 $T=10s$. 假定目标以常速运动,到 $k=40$ 时作 90 转弯,加速度为:

$$a_x(k) = a_y(k) = 0, \quad 0 \leq k < 39 \text{ 和 } 44 \leq k < 100;$$

$$a_x(k) = a_y(k) = 0.3, \quad 40 \leq k < 45; \text{ 初始值: } (2 \ 0.3 \ 0)$$

在 x 轴向上的运动轨迹如图 1(a) 所示. 设状态向量为 $X(k) = [x(k), \dot{x}(k), \ddot{x}(k)]^T$,

$$F = \begin{bmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \quad R(k) = \begin{bmatrix} T \\ \frac{T^2}{2} \\ \frac{T^3}{6} \end{bmatrix}, \quad R(k) = 0.001 I, \quad SNR = 85 \%$$

取初始值为 $(10, 0.5, 0.3)$, 采用 Kalman 滤波器与 STF 跟踪结果如图 1(a) 和误差如图 1(b) 所示.




图 1 两种跟踪结果比较

由图 1 容易看出,基于 STF 的 PDA 目标跟踪效果明显地比基于 KF 的 PDA 跟踪的效果好. KF 非常严重地依赖初始值的选取,从图中容易看出, KF 要经过很长时间摆脱初始值的影响;而 STF 却对初始值的选取不敏感,而且能很快跟上机动变化.

例 2 雷达对目标探测得到的测量是斜距 (R) 和方位 (θ) . 设状态向量为

$$X = [x \quad v_x \quad y \quad v_y]^T$$

则测量方程为

$$Y = h(X) = \begin{bmatrix} R \\ \theta \end{bmatrix} = \begin{bmatrix} (x^2 + y^2)^{1/2} \\ \tan^{-1}(y/x) \end{bmatrix}$$

线性化 h 得到

$$\begin{aligned} H_x(k) &= \left. \frac{\partial h}{\partial X} \right|_{x=X(k|k-1)} \\ &= \begin{bmatrix} \partial R / \partial x & \partial R / \partial v_x & \partial R / \partial y & \partial R / \partial v_y \\ \partial \theta / \partial x & \partial \theta / \partial v_x & \partial \theta / \partial y & \partial \theta / \partial v_y \end{bmatrix}_{x=X(k|k-1)} \\ &= \begin{bmatrix} \hat{x}(k|k-1)/R & 0 & \hat{y}(k|k-1)/R & 0 \\ -\hat{y}(k|k-1)/R^2 & 0 & \hat{x}(k|k-1)/R^2 & 0 \end{bmatrix} \end{aligned}$$

其中: $R = (\hat{x}^2(k|k-1) + \hat{y}^2(k|k-1))^{1/2}$, $SNR = 82.5 \%$.

在线性化过程中,从逼近理论的角度考虑,采样周期的大小对精度有影响.当采样周期较大时,应考虑取二次项以上,当采样周期较小时,高次项的影响较小,因此可以忽略.非线性情形下基于 STF 的 PDA 与基于 EKF 的 PDA 对目标的跟踪效果比较如图 2 所示.

从图 2 可以看出,虽然 EKF 能对目标的机动变化很好地




图2 非线性模型基于 EKF 和 STF 目标跟踪结果比较
适应,但当目标频繁地机动时,其跟踪精度明显地变差,甚至有发散的趋势.而 STF 却始终能较好地跟上目标的变化.

5 小结

本文提出了基于强跟踪滤波器理论的动态调整模型结构概率数据关联方法,给出了在强跟踪滤波器基础上的统计距离、状态估计、关联概率和更新方差矩阵的计算表达式.由于强跟踪滤波器通过引入渐消因子,强迫输出误差近似正交,动态调节协方差和增益矩阵,因而具有较好的鲁棒性,能够很好地适应目标状态突变的特性.此外,构造的动态调节系统过程的因子,能够根据目标的机动水平自适应变化,从而减小了模型匹配的不确定性,因而在跟踪机动目标,尤其是在跟踪状态变化较大的目标时,具有良好的应用前景.仿真实验结果表明,在初始值选择、适应目标频繁机动等方面,STF-PDA 的性能明显优于基于 EKF 的 PDA 的性能.

参考文献:

- [1] 周东华,席裕庚,张钟俊.一种带多重渐消因子的扩展卡尔曼滤波器[J].自动化学报,1991,17(6):34-38.
- [2] Blackman S S. Multiple-Target Tracking with Radar Application[M]. London:Artech House, Dedham, MA, 1986. 350-380.
- [3] Blackman S, Polli R. Design and Analysis of Modern Tracking Systems[M]. Artech House, 1999.
- [4] Bar-Shalom Y. Multitarget-Multisensor Tracking: Principles and Techniques[M]. 1995. 345-359.

- [5] Chen J, H Leung, Lo T, J Litva, Blanchette M. A Modified probabilistic data association filter in a real clutter environment [J]. IEEE Trans on Aerospace and Electronic Systems, 1996, 32(1):1657-1664.
- [6] Zhou B, Bose N K. Multitarget tracking in clutter fast algorithms for data association [J]. IEEE Transactions on Aerospace and Electronic Systems, 1993, 29(2):234-239.
- [7] Blom H A P. An Efficient Filter for Abruptly Changing System [A]. In Proceedings of the 23rd IEEE Conference on Decision and Control [C]. Las Vegas: IEEE, 1984. 1120-1127.
- [8] Blom H A P, Bar-Shalom Y. The interacting multiple model algorithm for systems with markovian switching coefficients [J]. IEEE Trans on Automatic Control, 1988, 33(8):780-783.
- [9] Li X R, Bar-Shalom Y. Multiple-model estimation with variable structure [J]. IEEE Transaction on Automatic Control, 1996, 41(4):478-493.
- [10] Maybeck P S. Stochastic Models, Estimation and Control [M]. New York: Academic Press, 1979. 287-292.
- [11] 周东华,叶银忠.现代故障诊断与容错控制[M].北京:清华大学出版社,2000.250-260.

作者简介:



徐 毓 男,1957 年生于江西都昌,教授,硕士研究生导师,清华大学博士研究生,主要从事雷达组网、目标跟踪、数据融合领域的研究,发表论文 35 篇.



杨瑞娟 女,1964 年生于四川新都,副教授,硕士研究生导师,华中科技大学博士研究生,主要从事雷达组网、数据通信领域的研究,发表论文 20 余篇.