

一种新的机动目标跟踪的多模型算法

范小军 刘 锋

(北京航空航天大学电子信息工程学院 北京 100083)

摘 要: 采用带渐消因子的“当前”统计模型与匀速运动模型进行交互,设计了一种新的机动目标跟踪的交互式多模型算法。“当前”统计模型具有对一般机动目标跟踪精度高的特点,通过渐消因子的引入增强了该模型对突发机动的自适应跟踪能力,同时通过与 CV 模型的交互保证了对非机动目标的跟踪性能。仿真结果表明,在跟踪一般机动目标时,其误差和“当前”统计模型与 CV 模型交互的 IMM 算法相当;在跟踪突发机动目标时,该文算法的误差明显小于“当前”统计模型与 CV 交互的 IMM 算法。

关键词: 机动目标跟踪;交互式多模型;卡尔曼滤波;强跟踪滤波器;“当前”统计模型

中图分类号: TN953

文献标识码: A

文章编号: 1009-5896(2007)03-0532-04

A New IMM Method for Tracking Maneuvering Target

Fan Xiao-jun Liu Feng

(School of Electronic Information Engineering, Beihang University, Beijing 100083, China)

Abstract: A new IMM algorithm for tracking maneuvering target is proposed, which uses a CS(Current Statistical) model with a fading factor and a CV(Constant Velocity) model for interaction. The CS model itself has a high precision when tracking common maneuvering target, its ability of tracking a sudden maneuvering target has been improved by introducing a fading factor of Strong Tracking Filter (STF), and the high precision to track non maneuvering targets can be ensured by interacting with the CV model. Simulation results show that, when there is only common maneuver the performance of the algorithm is the same with the IMM-CS/CV, when there is a sudden maneuver, the performance of this algorithm is much better than the IMM-CS/CV.

Key words: Maneuvering target tracking; IMM(Interacting Multiple Models); Kalman filter; Strong Tracking Filter; “Current” Statistical(CS) model

1 引言

在目标跟踪领域,机动目标跟踪一直是个难点和重点问题,原因在于很难建立精确的机动目标模型。在已有的动态模型中, Singer 模型^[1]及对其改进的“当前”统计模型^[2,3]被认为是目前对机动目标跟踪较为典型的模型。

由于目标实际运动的复杂性,难以单独采用一个模型来描述目标的运动。为此, Bar-shalom 和 Blom 等人在广义伪贝叶斯算法的基础上,提出了一种具有马尔可夫切换系数的交互式多模型(IMM)滤波算法^[4],其中多个模型并行工作,模型间以概率矩阵进行转移,目标状态估计是多个滤波器交互作用的结果,该算法不需要机动检测,达到了全面自适应能力,可以说 IMM 算法是目前机动目标跟踪中最有效的算法之一。

IMM 算法只有在精确选取模型时才能取得良好的效果^[5-8]。在 Bar-Shalom 等人所做的工作中,采用的大多数是匀加速模型或 Singer 模型与匀速模型进行交互作用。Singer 模

型把机动加速度描述成一个零均值的一阶马尔可夫过程。

“当前”统计模型则将 Singer 模型中加速度零均值改进为自适应的加速度均值,使得跟踪精度和性能得到较大提高,得到极为广泛的应用。但由于“当前”统计模型中目标的加速度变化范围有限,故当目标实际运动状态变化较大甚至发生突变时,其跟踪精度会显著下降^[9,10]。同时,由于“当前”统计模型算法中所采用的卡尔曼滤波器(KF)或扩展的卡尔曼滤波器(EKF)自身鲁棒性较差、对初值依赖性较大等原因,导致该模型受参数选择影响较大。

在故障检测领域,周东华等人提出了一种强跟踪滤波器算法(Strong Tracking Filter, STF)^[11,12],通过引进时变的渐消因子,动态调节增益矩阵,迫使输出残差近似正交,使得滤波器具有自适应地校正估计偏差和迅速跟踪状态变化的能力。与通常的滤波器相比,STF 具有以下优点:(1)对突变状态极强的跟踪能力;(2)鲁棒性较好;(3)计算复杂度适中。

本文提出了使用一个带有渐消因子的“当前”统计模型(简称 STFCS 模型)和一个常速(CV)模型组成模型集(略称 IMM-STFCS/CV 算法),实现对机动目标的有效跟踪。通过

渐消因子的引入,提高了“当前”统计模型对目标发生突发机动时的跟踪能力,但它对常速模型的跟踪精度较低。CV模型对于目标的常速运动是精确匹配的,跟踪精度较高;而对于机动运动,由于模型不匹配,导致跟踪精度相对较低。把这两个模型进行交互,则可以取长补短,对机动与非机动运动目标都实现高精度的跟踪。仿真结果验证了这一算法的有效性。与原当前统计模型和CV模型交互的IMM算法相比,本算法提高了目标突发机动时的跟踪能力,同时跟踪非机动和一般机动目标时性能保持不变。

2 系统模型描述

2.1 基于 STF 的“当前”统计模型和自适应跟踪算法 (STFCFS)

采用“当前”统计模型,一维情况下的离散状态方程为:

$$\mathbf{x}(k+1) = \mathbf{F}(k+1, k)\mathbf{x}(k) + \mathbf{U}(k)\bar{a}(k) + \mathbf{w}(k) \quad (1)$$

式中

$$\mathbf{x}(k) = [x(k), \dot{x}(k), \ddot{x}(k)]^T$$

$$\mathbf{F}(k+1, k) = \begin{pmatrix} 1 & T & \frac{1}{\alpha^2}(-1 + \alpha T + e^{-\alpha T}) \\ 0 & 1 & \frac{1}{\alpha}(1 - e^{-\alpha T}) \\ 0 & 0 & e^{-\alpha T} \end{pmatrix}$$

$$\mathbf{U}(k) = \begin{pmatrix} \frac{1}{\alpha} \left(-T + \frac{\alpha T^2}{2} + \frac{1 - e^{-\alpha T}}{\alpha} \right) \\ T - \frac{1 - e^{-\alpha T}}{\alpha} \\ 1 - e^{-\alpha T} \end{pmatrix}$$

式中 T 为采样周期。 $\bar{a}(k)$ 为“当前”加速度均值。 α 为机动时间常数的倒数(机动频率)。

测量方程为:

$$y(k+1) = \mathbf{H}(k+1)\mathbf{x}(k+1) + \mathbf{v}(k+1) \quad (2)$$

过程噪声 $\mathbf{w}(k)$ 和量测噪声 $\mathbf{v}(k)$ 是均值为零的高斯白噪声序列。 $\mathbf{H}(k+1)$ 为量测矩阵。

采用如下的强跟踪滤波器(STF)算法进行滤波,即得到了STFCFS算法:

$$\hat{\mathbf{x}}(k+1/k+1) = \hat{\mathbf{x}}(k+1/k) + \mathbf{K}(k+1)\mathbf{r}(k+1) \quad (3)$$

$$\hat{\mathbf{x}}(k+1/k) = \mathbf{F}(k+1, k)\mathbf{x}(k|k) + \mathbf{U}(k)\bar{a}(k) \quad (4)$$

$$\mathbf{K}(k+1) = \mathbf{P}(k+1|k)\mathbf{H}^T(k+1)[\mathbf{H}(k+1)\mathbf{P}(k+1|k) + \mathbf{H}^T(k+1) + \mathbf{R}(k)]^{-1} \quad (5)$$

$$\mathbf{P}(k+1|k) = \lambda(k+1)\mathbf{F}(k)\mathbf{P}(k|k)\mathbf{F}^T(k) + s \cdot \mathbf{\Gamma}(k)\mathbf{Q}(k)\mathbf{\Gamma}^T(k) \quad (6)$$

$$\mathbf{P}(k+1|k+1) = [\mathbf{I} - \mathbf{K}(k+1)\mathbf{H}(k+1)]\mathbf{P}(k+1|k) \quad (7)$$

式(6)中 $\lambda(k+1)$ 为渐消因子,为适合在线运算,一种次优的近似算法如下^[11]:

$$\lambda(k+1) = \begin{cases} \eta(k+1), & \eta(k+1) > 1 \\ 1, & \eta(k+1) \leq 1 \end{cases} \quad (8)$$

其中

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

$$\mathbf{N}(k+1) = \mathbf{V}_0(k+1) - \beta\mathbf{R}(k+1) - \mathbf{H}(k+1)\mathbf{\Gamma}(k) \cdot \mathbf{Q}(k)\mathbf{\Gamma}^T(k)\mathbf{H}^T(k+1)$$

$$\mathbf{M}(k+1) = \mathbf{H}(k+1)\mathbf{F}(k)\mathbf{P}(k|k)\mathbf{F}^T(k)\mathbf{H}^T(k+1)$$

$\mathbf{V}_0(k+1)$ 是残差方差矩阵

$$\mathbf{V}_0(k+1) = E[\mathbf{r}(k+1)\mathbf{r}^T(k+1)]$$

$$= \begin{cases} \mathbf{r}(1)\mathbf{r}^T(1), & k=0 \\ \frac{\rho\mathbf{V}_0(k) + \mathbf{r}(k+1)\mathbf{r}^T(k+1)}{1+\rho}, & k \geq 1 \end{cases} \quad (9)$$

$0 < \rho \leq 1$ 是遗忘因子,一般取 $\rho = 0.95$ 。 β 是弱化因子,可根据经验值来选定。 $\mathbf{r}(1)$ 是初始残差。

把 $\hat{x}(k)$ 的一步预测 $\hat{x}(k|k-1)$ 看作在 kT 时刻的“当前”加速度即随机机动加速度的均值 $\bar{a}(k)$,就可得到系统噪声方差计算式为,

$$\sigma_a^2 = \begin{cases} \frac{4-\pi}{\pi} [a_{\max} - \hat{x}(k|k-1)]^2, & \hat{x}(k|k-1) > 0 \\ \frac{4-\pi}{\pi} [a_{-\max} + \hat{x}(k|k-1)]^2, & \hat{x}(k|k-1) < 0 \end{cases} \quad (10)$$

将 $\mathbf{F}(k+1, k)$ 和 $\mathbf{U}(k)$ 代入式(4)后得到:

$$\hat{\mathbf{x}}(k+1/k) = \mathbf{F}_1(T)\hat{\mathbf{x}}(k/k) \quad (11)$$

其中

$$\mathbf{F}_1(T) = \begin{pmatrix} 1 & T & \frac{T^2}{2} \\ 0 & 1 & T \\ 0 & 0 & 1 \end{pmatrix} \quad (12)$$

STFCFS算法借鉴强跟踪滤波器的思想,通过引入时变的渐消因子 $\lambda(k+1)$,促使测量残差近似正交,使得滤波器关于模型不确定保持了较好的鲁棒性。并根据输出残差 $\mathbf{r}(k)$ 实时调节过程噪声方差 $\mathbf{P}(k+1|k)$ 和系统增益 $\mathbf{K}(k)$,增大了目标状态估计的补偿值,从而提高对机动目标估计和跟踪精度。

在跟踪一般机动目标时,输出残差方差较小,使得渐消因子 $\lambda(k+1)$ 为1,此时本算法退化为原“当前”统计模型及自适应算法,保持了对一般机动目标的较高跟踪精度。在目标发生突发机动或者机动加速度变化较大时,强跟踪滤波器根据残差的增大而增大渐消因子,自适应地调节增益,迫使残差近似正交,从而提高状态突变时的跟踪性能。整体上STFCFS算法可以较好的自适应跟踪大小机动目标。

强跟踪滤波器(STF)本身是收敛的, 基于STF的“当前”统计模型及自适应算法STFCS仍然保持了原“当前”统计模型及自适应跟踪算法的收敛性。

2.2 常速模型(CV)

采用常速模型, 一维情况下的离散状态方程为:

$$\mathbf{x}(k+1) = \mathbf{F}_{cv}(k+1, k)\mathbf{x}(k) + \mathbf{G}_{cv}^a \mathbf{w}(k) \quad (13)$$

其中

$$\mathbf{F}_{cv}^a(k+1/k) = \begin{pmatrix} 1 & T & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

$$\mathbf{G}_{cv}^a = \begin{pmatrix} T^2/2 \\ T \\ 1 \end{pmatrix}$$

过程噪声 $\mathbf{w}(k)$ 是一零均值的高斯白噪声序列。

3 交互式多模型算法(IMM 算法)

交互式多模型算法是一种递归算法, 在每个周期内有多个滤波器同时工作。这里我们用两个滤波器, STFCS模型用于描述目标的机动运动, CV模型用于描述目标的匀速运动。IMM算法的每一步包含4个主要的步骤: 输入交互、滤波、模型概率更新、输出交互^[4, 5]。

步骤1 输入交互 对于第 j 个模型, 有:

$$\hat{\mathbf{x}}_j^0(k|k) \triangleq E[\mathbf{x}(k) | \mathbf{m}_j(k+1), \mathbf{Z}^k] = \sum_{i=1}^m u_{ij}(k) \cdot \hat{\mathbf{x}}_i(k|k) \quad (14)$$

$$\mathbf{P}_j^0(k|k) \triangleq E\{[\hat{\mathbf{x}}_j(k|k) - \mathbf{x}(k)] \cdot [\cdot]^T | \mathbf{m}_j(k+1), \mathbf{Z}^k\} \\ = \sum_{i=1}^m u_{ij}(k) \{P_i(k|k) + [\hat{\mathbf{x}}_i(k|k) - \hat{\mathbf{x}}_j^0(k|k)] \cdot [\cdot]^T\} \quad (15)$$

$$u_j^0(k) \triangleq \mathbf{P}\{m_j(k+1) | \mathbf{Z}^k\} = \sum_{i=1}^m \pi_{ij} \cdot u_i(k) \quad (16)$$

其中

$$u_{ij}(k) \triangleq \mathbf{P}\{m_i(k) | m_j(k+1), \mathbf{Z}^k\} = \frac{1}{c_j(k)} \cdot \pi_{ij} \cdot u_i(k)$$

$$c_j(k) = \sum_{i=1}^m \pi_{ij} \cdot u_i(k)$$

步骤2 滤波计算 将 $\hat{\mathbf{x}}_j(k|k)$ 和 $\mathbf{P}_j^0(k|k)$ 代入基于第 j 个模型的滤波器, 从而获得: 状态估计及其协方差分别为 $\hat{\mathbf{x}}_j(k+1|k+1)$ 和 $\mathbf{P}_j(k+1|k+1)$, 残差及其协方差分别为 $\delta_j(k+1)$ 和 $\mathbf{S}_j(k+1)$ 。

步骤3 模型概率更新 对于第 j 个模型, 其似然函数为:

$$A_j(k+1) \triangleq \mathbf{P}\{z(k+1) | m_j(k+1), \mathbf{Z}^k\} \\ = N[\delta_j(k+1); 0, \mathbf{S}_j(k+1)] \quad (17)$$

式中 $N[*]$ 为正态分布密度函数。

模型更新方程为:

$$u_j(k+1) = \mathbf{P}\{m_j(k+1) | \mathbf{Z}^{k+1}\} \\ = \frac{1}{c(k+1)} A_j(k+1) \cdot u_j^0(k) \quad (18)$$

其中

$$c(k+1) = \sum_{j=1}^m A_j(k+1) \cdot u_j^0(k)$$

步骤4 输出交互

$$\hat{\mathbf{x}}(k+1|k+1) = E[\mathbf{x}(k+1) | \mathbf{Z}^{k+1}] \\ = \sum_{j=1}^m \hat{\mathbf{x}}_j(k+1|k+1) \cdot u_j(k+1) \quad (19)$$

$$P(k+1|k+1) = \sum_{j=1}^m \{P_j(k+1|k+1) \\ + [\hat{\mathbf{x}}_j(k+1|k+1) - \hat{\mathbf{x}}(k+1|k+1)] \cdot [\cdot]^T\} \\ \cdot u_j(k+1) \quad (20)$$

强跟踪滤波器(STF)通过在线调整增益 $\mathbf{K}(k+1)$, 使得(1)均方误差最小; (2)输出残差近似为高斯白噪声^[11]。经证明, 当模型与实际系统完全匹配时, Kalman滤波器的输出残差序列是不自相关的高斯白噪声序列, 因此当目标状态发生突变时, 强跟踪滤波器仍能较好地保持对目标实际状态跟踪^[12]。所以, 将强跟踪滤波器引入原“当前”统计模型与常速模型交互的IMM算法能提高算法的跟踪精度。

4 仿真结果

通过 Monte-Carlo 仿真来验证算法的有效性。假设测量噪声符合零均值高斯分布。本算法的模型集合由两个模型组成: 一个使用带渐消因子的“当前”统计模型 STF-CS 和一个 CV 模型。与本算法对比的 IMM-CS/CV 算法采用一个“当前”统计模型和一个 CV 模型进行交互。用这两种算法对两种不同的典型运动航迹进行模拟, 采样周期 $T_s = 1s$ 。两种算法采用的马尔可夫转移概率矩阵均为

$$\pi_{ij} = \begin{pmatrix} 0.8 & 0.2 \\ 0.2 & 0.8 \end{pmatrix}$$

仿真场景1: 目标只发生小机动的情况。目标在 $1km \leq k < 150km$ 时作 $v = 0.5km/s$ 的匀速直线运动, 在 $150km \leq k < 200km$ 时作 $a = 0.01km/s^2$ 的匀加速直线运动, 在 $200km \leq k < 390km$ 时在 $v = 1km$ 的匀速直线运动;

仿真场景2: 目标发生突发机动的情况。目标在 $1km \leq k < 100km$ 时作 $v = 0.5km/s$ 的匀速直线运动; 在 $100km \leq k < 120km$ 时作 $a = 0.5km/s^2$ 的匀加速直线运动; 在 $120km \leq k < 220km$ 时作 $v = 2.5km/s$ 的匀速直线运动。

图1和图2分别给出了本文提出的IMM-STFCS/CV算法、传统IMM-CS/CV算法在上面两种情况下的仿真结果。

图1中的小图是两种算法的误差相对值曲线, 可以看到, 此种情况下两算法的误差较为接近。

从图1可以看出, 当目标作非机动运动或者只发生小机动时, IMM-STFCS/CV 算法跟踪效果与 IMM-CS/CV 算

法相当。这是因为此种情况下渐消因子始终为 1，不起到调节作用。本文算法退化为原 IMM-CS/CV 算法。

从图 2 可以看出，当目标作突发机动时，IMM-CS/CV 算法会发生发散现象，而 IMM-STFCS/CV 算法能很好地抑制发散。这时因为在发生突发机动时，IMM-STFCS/CV 算法能通过渐消因子根据残差自适应调整增益，使算法始终保持对目标状态的跟踪。




图 1 目标作小机动运动时的跟踪结果




图 2 目标作大机动运动时的跟踪结果

5 结束语

本文在“当前”统计模型的基础上引入强跟踪滤波器的渐消因子，根据残差动态地调节增益，迫使输出残差近似正交，增强了目标发生状态突变时的跟踪能力，同时跟踪一般机动目标时性能保持不变。再将此模型与常速模型进行交互，使系统增强了对非机动运动目标跟踪能力，达到了全面自适应跟踪。仿真结果表明，与原“当前”统计模型与常速模型交互的 IMM 算法相比，本算法明显提高了跟踪突发机动目标的性能，具有较好的应用前景。

参 考 文 献

[1] Singer R A. Estimating optimal tracking filter performance for manned maneuvering targets[J]. *IEEE Trans. on*

Aerospace and Electronic Systems, 1970, AES-6(4): 473-483.
 [2] 周宏仁, 敬忠良, 王培德. 机动目标跟踪[M]. 北京: 国防工业出版社, 1991: 134-176.
 [3] Zhou H R and Kumar K S P. A current statistical model and adaptive algorithm for estimating maneuvering targets [J]. *AIAA Journal of Guidance*, 1984, 7(5): 596-602.
 [4] Blom H A P and Bar-Shalom Y. The interactive multiple model algorithm for system with markov switching coefficients [J]. *IEEE Trans. on Automatic Control*, 1988, 33(8): 780-783.
 [5] Li X R and Bar-Shalom Y. Performance prediction of the interacting multiple model algorithm [J]. *IEEE Trans. on Aerospace and Electronics*, 1993, 29(13): 755-771.
 [6] Chen Ling and Li Shaohong. IMM tracking of 3D maneuvering target with passive TDOA system[J]. *IEEE Int. Conf. Neural Networks & Signal Processing*, Nanjing, China, 2003: 1611-1614.
 [7] Mazor E, et al.. Interacting multiple model methods in multiple-multiple tracking: a survey [J]. *IEEE Trans. on AES*, 1998, 34 (1): 103-122.
 [8] Jikov V P, Angelova D S, and Semerdjiev T A. Design and comparison of mode-set adaptive IMM algorithms for maneuvering target tracking. *IEEE Trans. on Aerospace and Electronic Systems*, 1999, 35(1): 343-350.
 [9] 敬忠良, 徐宏, 周雪琴等. 基于神经网络的机动目标信息融合与并行自适应跟踪[J]. *航空学报*, 1995, 16(6): 715-719.
 [10] 嵇成新, 张永胜. 机动目标跟踪的一种模糊算法[J]. *现代雷达*, 2002, 11(6): 35-38.
 Ji Cheng-xin and Zhang Yong-sheng. A fuzzy algorithm for maneuvering target tracking. *Modern Radar*, 2002, 11(6): 35-38.
 [11] Zhou D H and Frank P M. Strong tracking filtering of nonlinear time-varying stochastic systems with colored noise: application to parameter estimation and empirical robustness analysis [J]. *IEEE Int. J Control*, 1996, 65(2): 295-307.
 [12] 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.

范小军: 男, 1982 年生, 硕士生, 研究方向为机动目标跟踪、无源定位。
 刘 锋: 男, 1970 年生, 副教授, 博士, 目前感兴趣的研究方向主要有天空地一体化通信网络和互联网络动力学及其控制。