

自适应转移概率交互式 多模型跟踪算法

许登荣,程水英,包守亮

(国防科技大学电子对抗学院,安徽合肥 230037)

摘 要: 针对标准的交互式多模型算法(Interacting Multiple Model, IMM)存在模型集设计困难和采用固定转移概率矩阵导致模型切换缓慢、跟踪精度下降的不足,提出一种自适应转移概率 IMM 算法. 首先,提出了一种新的模型集设计方法,将强跟踪修正输入估计(Strong Tracking Modified Input Estimation, STMIE)模型和匀速运动(Constant Velocity, CV)模型作为 IMM 算法的模型集,利用 STMIE 算法对高机动目标的跟踪能力以及 CV 模型对非机动目标跟踪的高精度,实现对目标的全面自适应跟踪. 其次,提出一种依据模型似然函数值对 Markov 转移概率进行实时修正的方法,增强匹配模型的作用,削弱不匹配模型的影响. 仿真结果表明,依据模型似然函数修正转移概率的方法使 IMM 算法的模型切换速度和跟踪精度都得到提高,提出的 IMM-STMIECV 算法的跟踪精度高于 IMM-CVCA、IMM-CVCACT 以及 IMM-CVCS 算法.

关键词: 机动目标跟踪; 交互式多模型算法; Markov 转移概率; 修正的输入估计法; 强跟踪

中图分类号: TN95 **文献标识码:** A **文章编号:** 0372-2112 (2017)09-2113-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.09.009

Interacting Multiple Model Algorithm Based on Adaptive Transition Probability

XU Deng-rong, CHENG Shui-ying, BAO Shou-liang

(Institute of Electronic Countermeasure, National University of Defense Technology, Hefei, Anhui 230037, China)

Abstract: There are two shortcomings in the standard interacting multiple model (IMM) algorithm: one is that designing models is difficult, the other is that the application of constant transition probability matrices makes the model switching speed slow and tracking accuracy decreased. To overcome these shortcomings, an IMM algorithm with adaptive transition probability is proposed. Firstly, a new model-set design method is proposed, and the strong tracking modified input estimation (STMIE) model and constant velocity (CV) model are adopted as the model sets of the IMM algorithm. By using the capability of STMIE model to track high maneuvering targets and the precision of CV model to track non-maneuvering targets, this algorithm can be comprehensively adaptive in target tracking. Secondly, a new method is proposed to modify the Markov transition probability in real time based on the likelihood values of the models, which enhances the effect of the matching model, and weakens the influence of the mismatched model. Simulation results show that the new method improves model switching speed and tracking precision of IMM algorithm, and the tracking precision of IMM-STMIECV algorithm is higher than that of IMM-CVCA, IMM-CVCACT and IMM-CVCS algorithms.

Key words: maneuvering target tracking; interacting multiple model (IMM); markov transition probability; modified input estimation (MIE); strong tracking filter (STF)

1 引言

机动目标跟踪^[1~5]是目标跟踪领域的重点和难点问题,相关学者对此问题展开了广泛的研究. 最开始采用的是自适应单模型算法对机动目标进行跟踪,然后发展为带机动检测的单模型跟踪算法,紧接着的是多

模型算法,并逐渐成为机动目标跟踪的主流方法. 多模型算法总结起来可分为三代^[6]: 自主多模型(Autonomous Multiple Model, AMM)估计、协作式多模型(Cooperating Multiple Model, CMM)估计、变结构多模型(Variable-Structure Multiple Model, VSMM)估计. 在所有的多模型算法中,IMM 算法通过合理的假设管理,一般被认

为是混合系统中有效的混合估计方式,并得到了广泛的应用^[7-9].

虽然 IMM 算法被成功地应用,但是 IMM 算法跟踪性能仍受两个方面的限制. 第一,由于 IMM 采用固定模型集,而现有的目标跟踪算法大多是基于模型的,因而 IMM 算法跟踪性能的好坏很大程度取决于所选的模型集. 模型集的选择存在这样一个困境,即为了提高滤波精度需要尽可能多的增加模型,但是太多的模型除了大大增加计算量之外,反而降低了估计器的性能. 第二,IMM 算法中的 Markov 转移概率矩阵决定着输入交互的作用程度,一般根据先验信息人为选取为固定的主对角占优矩阵^[10],不能依据后验信息对转移概率进行实时调整,不符合实际情况. 当先验信息不确定时,采用固定 Markov 转移概率矩阵会造成跟踪精度的下降,因此,对 Markov 转移概率的实时估计一直是国内外研究的一个热点问题^[10-13].

本文针对 IMM 算法性能受限的两个方面而展开研究. 首先,为了弥补 IMM 算法在模型集设计方面的不足,提出一种新颖的模型集设计方法. 将 STMIE 算法与 IMM 算法相结合,把 STMIE 模型和 CV 模型作为 IMM 算法的模型集,利用 STMIE 算法对高机动目标的跟踪能力以及 CV 模型对非机动目标跟踪的高精度,实现对目标的全面自适应跟踪;同时针对 STMIE 算法采取扩维方法估计目标机动加速度导致与 CV 模型的状态向量维数不一致,采用无偏混合^[14]方法. 其次,针对采用 IMM 算法采取固定 Markov 转移概率矩阵会造成跟踪精度的下降的问题,提出一种简单有效的依据模型似然函数值在线修正转移概率的方法,并给出相应的递推公式. 仿真结果校验了本文算法的优越性.

2 STMIE 算法

2.1 修正的输入估计 (Modified Input Estimation, MIE) 算法

在无先验信息条件下,假设机动目标离散的状态方程和量测方程可表示为:

$$\begin{cases} \mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{G}_k \mathbf{u}_k + \mathbf{\Gamma}_k \mathbf{w}_k \\ \mathbf{z}_{k+1} = \mathbf{H}_{k+1} \mathbf{x}_{k+1} + \mathbf{v}_{k+1} \end{cases} \quad (1)$$

式中: $\mathbf{F}_k$ 为状态转移矩阵; $\mathbf{G}_k$ 为输入控制矩阵; $\mathbf{\Gamma}_k$ 为过程噪声分布矩阵; $\mathbf{H}_{k+1}$ 为量测矩阵; $\mathbf{u}_k$ 为目标未知的加速度; $\mathbf{w}_k$ 、 $\mathbf{v}_k$ 分别为零均值的白色过程噪声和量测噪声序列,协方差矩阵分别为 $\mathbf{Q}_k$ 和 $\mathbf{R}_k$,且任意时刻的 $\mathbf{w}_k$ 与 $\mathbf{v}_k$ 不相关.

以二维情况为例,假设 $\mathbf{x}_k = [x_k \dot{x}_k y_k \dot{y}_k]^T$ 为 k 时刻目标的状态向量, $\mathbf{z}_k = [x_k \ y_k]^T$ 为观测向量,则:

$$\mathbf{F}_k = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{G}_k = \mathbf{\Gamma}_k = \begin{bmatrix} \frac{T^2}{2} & T & 0 \\ 0 & 0 & \frac{T^2}{2} \end{bmatrix}^T \quad (2)$$

$$\mathbf{H}_{k+1} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}, \mathbf{u}_k = [\ddot{x}_k \ \ddot{y}_k]^T \quad (3)$$

其中 T 为采样间隔,由于 $\mathbf{F}_k$ 、 $\mathbf{G}_k$ 、 $\mathbf{\Gamma}_k$ 、 $\mathbf{H}_{k+1}$ 为时不变矩阵,为方便起见,省略时间下标,下文中简称为 $\mathbf{F}$ 、 $\mathbf{G}$ 、 $\mathbf{\Gamma}$ 、 $\mathbf{H}$. 若将未知输入向量 $\mathbf{u}_k$ 扩展为状态向量 $\mathbf{x}_k$ 的一个新的分量,就可将式(1)的机动目标状态方程转化为非机动的目标状态方程,扩展的状态方程为^[4]:

$$\begin{bmatrix} \mathbf{x}_{k+1} \\ \mathbf{u}_{k+1} \end{bmatrix} = \begin{bmatrix} \mathbf{F} & \mathbf{G} \\ \mathbf{O} & \mathbf{I} \end{bmatrix} \begin{bmatrix} \mathbf{x}_k \\ \mathbf{u}_k \end{bmatrix} + \begin{bmatrix} \mathbf{\Gamma} \\ \mathbf{O} \end{bmatrix} \mathbf{w}_k \quad (4)$$

量测方程为:

$$\begin{aligned} \mathbf{z}_{k+1} &= \mathbf{H} \mathbf{x}_{k+1} + \mathbf{v}_{k+1} = \mathbf{H}(\mathbf{F} \mathbf{x}_k + \mathbf{G} \mathbf{u}_k + \mathbf{\Gamma} \mathbf{w}_k) + \mathbf{v}_{k+1} \\ &= [\mathbf{H} \mathbf{F} \ \mathbf{H} \mathbf{G}] [\mathbf{x}_k \ \mathbf{u}_k]^T + \mathbf{H} \mathbf{\Gamma} \mathbf{w}_k + \mathbf{v}_{k+1} \end{aligned} \quad (5)$$

定义: $\mathbf{x}_k^{\text{Aug}} \triangleq \begin{bmatrix} \mathbf{x}_k \\ \mathbf{u}_k \end{bmatrix}$, $\mathbf{F}_k^{\text{Aug}} \triangleq \begin{bmatrix} \mathbf{F} & \mathbf{G} \\ \mathbf{O} & \mathbf{I} \end{bmatrix}$, $\mathbf{\Gamma}_k^{\text{Aug}} \triangleq [\mathbf{\Gamma} \ \mathbf{O}]^T$, $\mathbf{z}_k^{\text{Aug}} \triangleq \mathbf{z}_k$, $\mathbf{H}_k^{\text{Aug}} \triangleq [\mathbf{H} \mathbf{F} \ \mathbf{H} \mathbf{G}]$, $\mathbf{w}_k^{\text{Aug}} \triangleq \mathbf{w}_k$, $\mathbf{v}_k^{\text{Aug}} \triangleq \mathbf{H} \mathbf{\Gamma} \mathbf{w}_k + \mathbf{v}_{k+1}$.

则可得扩维后的状态方程和量测方程:

$$\mathbf{x}_{k+1}^{\text{Aug}} = \mathbf{F}_k^{\text{Aug}} \mathbf{x}_k^{\text{Aug}} + \mathbf{\Gamma}_k^{\text{Aug}} \mathbf{w}_k^{\text{Aug}} \quad (6)$$

$$\mathbf{z}_k^{\text{Aug}} = \mathbf{z}_{k+1} = \mathbf{H}_k^{\text{Aug}} \mathbf{x}_k^{\text{Aug}} + \mathbf{v}_k^{\text{Aug}} \quad (7)$$

由式(6)、(7)即可利用卡尔曼滤波对目标的状态进行递推估计.

2.2 强跟踪多重渐消因子

在目标高机动或连续机动时,目标的加速度幅度变化大,容易造成滤波器发散. 文献[5]结合强跟踪思想对 MIE 算法进行了改进. 即引入强跟踪滤波器时变的多重渐消因子对滤波器的预测协方差矩阵进行调整,进而调节滤波器的增益矩阵. 引入多重渐消因子的一步预测协方差矩阵的计算公式为:

$$\mathbf{P}_{k+1|k}^{\text{Aug}} = \lambda_{k+1} \mathbf{F}_k^{\text{Aug}} \mathbf{P}_{k|k}^{\text{Aug}} (\mathbf{F}_k^{\text{Aug}})^T + \mathbf{\Gamma}_k^{\text{Aug}} \mathbf{Q}_k (\mathbf{\Gamma}_k^{\text{Aug}})^T \quad (8)$$

而 $\lambda_{k+1} = \text{diag}(\lambda_{k+1}^1, \lambda_{k+1}^2, \dots, \lambda_{k+1}^n)$ 可采用如下计算方法:

$$\lambda_{k+1}^i = \begin{cases} \alpha_i C_{k+1}, & \alpha_i C_{k+1} > 1 \\ 1, & \alpha_i C_{k+1} \leq 1 \end{cases}, C_{k+1} = \frac{\text{tr}(\mathbf{N}_{k+1})}{\sum_{i=1}^n \alpha_i M_{k+1}^{ii}} \quad (9)$$

$$\mathbf{N}_{k+1} = \mathbf{V}_{k+1} - \mathbf{H}_{k+1}^{\text{Aug}} \mathbf{\Gamma}_k^{\text{Aug}} \mathbf{Q}_k (\mathbf{\Gamma}_k^{\text{Aug}})^T (\mathbf{H}_{k+1}^{\text{Aug}})^T - \eta \mathbf{R}_{k+1}^{\text{Aug}} \quad (10)$$

$$\mathbf{M}_{k+1} = \mathbf{F}_k^{\text{Aug}} \mathbf{P}_{k|k}^{\text{Aug}} (\mathbf{F}_k^{\text{Aug}})^T (\mathbf{H}_{k+1}^{\text{Aug}})^T \mathbf{H}_{k+1}^{\text{Aug}} \quad (11)$$

式中: tr 为求矩阵迹的算子; $\alpha_i \geq 1$ ($i = 1, 2, \dots, n$) 均为预先选定的常数,由先验信息确定; η 为弱化因子,可以使状态估计值更加的平滑,通常根据经验选取; $\mathbf{M}_{k+1}^{ii}$ 为矩阵 $\mathbf{M}_{k+1}$ 的对角线元素; $\mathbf{V}_{k+1}$ 为实际输出残差序列的

协方差矩阵,在实际中是未知的,可通过下式进行估算:

$$V_{k+1} = \begin{cases} \boldsymbol{\varepsilon}_1^{\text{Aug}} (\boldsymbol{\varepsilon}_1^{\text{Aug}})^T, & k=0 \\ \frac{\rho V_k + \boldsymbol{\varepsilon}_{k+1}^{\text{Aug}} (\boldsymbol{\varepsilon}_{k+1}^{\text{Aug}})^T}{1+\rho}, & k \geq 1 \end{cases} \quad (12)$$

$$\boldsymbol{\varepsilon}_{k+1}^{\text{Aug}} = \mathbf{z}_{k+1}^{\text{Aug}} - \mathbf{H}_{k+1}^{\text{Aug}} \mathbf{x}_{k+1|k}^{\text{Aug}} \quad (13)$$

式中 $\boldsymbol{\varepsilon}_{k+1}^{\text{Aug}}$ 为理论输出的残差序列, $0 < \rho \leq 1$ 为遗忘因子,通常取 $\rho = 0.95$.

2.3 强跟踪输入估计算法滤波步骤

由上面的分析可以得到 STMIE 算法滤波流程如下^[4,5]:

步骤 1 一步预测

状态的一步预测:

$$\hat{\mathbf{x}}_{k+1|k}^{\text{Aug}} = \hat{\mathbf{F}}_k^{\text{Aug}} \mathbf{x}_{k|k}^{\text{Aug}} \quad (14)$$

协方差的一步预测为:

$$\mathbf{P}_{k+1|k}^{\text{Aug}} = \lambda_{k+1} \mathbf{F}_k^{\text{Aug}} \mathbf{P}_{k|k}^{\text{Aug}} (\mathbf{F}_k^{\text{Aug}})^T + \mathbf{I}_k^{\text{Aug}} \mathbf{Q}_k (\mathbf{I}_k^{\text{Aug}})^T \quad (15)$$

步骤 2 一步更新

状态的一步更新

$$\hat{\mathbf{x}}_{k+1|k+1}^{\text{Aug}} = \hat{\mathbf{x}}_{k+1|k}^{\text{Aug}} + \mathbf{K}_{k+1}^{\text{Aug}} (\mathbf{z}_{k+1}^{\text{Aug}} - \mathbf{H}_{k+1}^{\text{Aug}} \hat{\mathbf{x}}_{k+1|k}^{\text{Aug}}) \quad (16)$$

协方差的一步更新

$$\mathbf{P}_{k+1|k+1}^{\text{Aug}} = \mathbf{P}_{k+1|k}^{\text{Aug}} - \mathbf{P}_{k+1|k}^{\text{Aug}} (\mathbf{H}_{k+1}^{\text{Aug}})^T (\mathbf{S}_{k+1}^{\text{Aug}})^{-1} \mathbf{H}_{k+1}^{\text{Aug}} \mathbf{P}_{k+1|k}^{\text{Aug}} \quad (17)$$

其中

$$\mathbf{S}_{k+1}^{\text{Aug}} = \mathbf{H}_{k+1}^{\text{Aug}} \mathbf{P}_{k+1|k}^{\text{Aug}} (\mathbf{H}_{k+1}^{\text{Aug}})^T + \mathbf{R}_{k+1}^{\text{Aug}} \quad (18)$$

$$\mathbf{K}_{k+1}^{\text{Aug}} = [\mathbf{P}_{k+1|k}^{\text{Aug}} (\mathbf{H}_{k+1}^{\text{Aug}})^T + \mathbf{I}_k^{\text{Aug}} \mathbf{T}_k^{\text{Aug}}] (\mathbf{R}_{k+1}^{\text{Aug}})^{-1} \quad (19)$$

$$\mathbf{T}_k^{\text{Aug}} = \mathbf{Q}_k \mathbf{I}_k^{\text{Aug}T} \mathbf{H}_k^T \quad (20)$$

$$\begin{aligned} \mathbf{R}_{k+1}^{\text{Aug}} &= \mathbf{E}[\mathbf{v}_{k+1}^{\text{Aug}} (\mathbf{v}_{k+1}^{\text{Aug}})^T] \\ &= \mathbf{E}[(\mathbf{H} \mathbf{F} \mathbf{w}_{k+1} + \mathbf{v}_{k+2}) (\mathbf{H} \mathbf{F} \mathbf{w}_{k+1} + \mathbf{v}_{k+2})^T] \\ &= \mathbf{H} \mathbf{I} \mathbf{Q}_{k+1} \mathbf{I}^T \mathbf{H}^T + \mathbf{R}_{k+2} \end{aligned} \quad (21)$$

由式(19)可知,扩维后滤波器的增益 $\mathbf{K}_{k+1}^{\text{Aug}}$ 由预测协方差矩阵 $\mathbf{P}_{k+1|k}^{\text{Aug}}$ 和 $\mathbf{T}_k^{\text{Aug}}$ 共同决定. 通常当目标高机动时,滤波器的残差迅速增大,一步预测协方差 $\mathbf{P}_{k+1|k}^{\text{Aug}}$ 可以通过多重渐消因子矩阵 λ_{k+1} 而及时调整,进而使滤波增益 $\mathbf{K}_{k+1}^{\text{Aug}}$ 能得到合理地调整,显著增强了 MIE 算法对高机动目标的跟踪能力.

3 IMM-STMIECV 算法及步骤

3.1 IMM-STMIECV 算法

模型集的设计是多模型估计中最重要的问题之一,传统的 IMM 算法一般选用 CV 模型和匀加速度 (Constant Acceleration, CA) 模型的组合作为模型集进行混合估计或者选用 CV 模型、CA 模型以及转弯速率未知的协同转弯 (Coordinate Turn, CT) 模型^[15] 作为模型集进行混合估计,来实现对目标非机动时的精确跟踪以及目标加速或转弯机动时的跟踪. 另外采用相关噪声模型 (如当前统计 (Current Statistical, CS) 模型) 和 CV 模型的组合也比较常见,但当目标高机动时或者连续

机动时,往往会因为模型竞争或模型不匹配导致滤波估计精度不理想.

STMIE 算法在目标多种机动情况下相比其他通用型跟踪算法拥有更高的跟踪精度,但降低了对非机动目标的滤波精度,因而从理论上来说,选用 STMIE 模型和 CV 模型的组合的作为 IMM 算法的模型集就能实现对目标的全面自适应跟踪,并记采用这种模型集设计的 IMM 算法为 IMM-STMIECV 算法. 但由于二维空间中 CV 模型的状态维数为 4,而 STMIE 模型扩维后状态向量的维数为 6,状态维数不一致,而 IMM 算法要实现状态和协方差的混合交互,所有状态向量必须转换成一致的状态变量^[16]. 模型状态维数不同以及状态元素不一致时如何实现 IMM 算法的混合估计在文献[14,16,17]都有所提及,本文采用的是文献[14]提出的无偏混合方法,该算法在混合估计过程中不会带来偏差,且具有更好的一致性.

3.2 IMM-STMIECV 算法步骤

IMM 估计算法是递推进行的. 每步递推包括 4 个步骤,即模型条件重初始化、模型条件滤波、模型概率更新、估计融合. 现给出 IMM-STMIECV 算法由 $k-1$ 时刻到 k 时刻的递推步骤.

步骤 1 模型条件重初始化

首先计算混合概率,然后采用 2.1 节介绍的无偏混合方法进行混合估计,即可得到重初始化的状态和协方差矩阵.

步骤 2 模型条件滤波

由步骤 1 得到 CV 模型和 STMIE 模型估计的初始条件. 然后每个模型按如下步骤进行递推

$$\hat{\mathbf{x}}_{k|k-1}^j = \mathbf{F}_{k-1}^j \hat{\mathbf{x}}_{k-1|k-1}^{0j} \quad (22)$$

$$\mathbf{P}_{k|k-1}^j = \mathbf{F}_{k-1}^j \mathbf{P}_{k-1|k-1}^{0j} (\mathbf{F}_{k-1}^j)^T + \mathbf{Q}_{k-1}^j \quad (23)$$

$$\hat{\mathbf{x}}_{k|k}^j = \hat{\mathbf{x}}_{k|k-1}^j + \mathbf{K}_k^j (\mathbf{z}_k - \mathbf{H}_k^j \hat{\mathbf{x}}_{k|k-1}^j) \quad (24)$$

$$\mathbf{P}_{k|k}^j = \mathbf{P}_{k|k-1}^j - \mathbf{K}_k^j \mathbf{S}_k^j (\mathbf{K}_k^j)^T \quad (25)$$

其中

$$\mathbf{K}_k^j = \mathbf{P}_{k|k-1}^j (\mathbf{H}_k^j)^T (\mathbf{S}_k^j)^{-1} \quad (26)$$

$$\mathbf{S}_k^j = \mathbf{H}_k^j \mathbf{P}_{k|k-1}^j (\mathbf{H}_k^j)^T + \mathbf{R}_k^j \quad (27)$$

式(22)~(27)中,上标 j 表示其中的第 j 个模型,下同, $j \in \{1, 2, \dots, M\}$, M 为模型总个数,此处 $M=2$.

步骤 3 模型概率更新

$$\begin{aligned} \mu_k^j &= \Pr\{r_k = j | \mathbf{Z}^k\} \\ &= \frac{p(\mathbf{z}_k | r_k = j, \mathbf{Z}^{k-1}) \Pr\{r_k = j | \mathbf{Z}^{k-1}\}}{\sum_{l=1}^M p(\mathbf{z}_k | r_k = l, \mathbf{Z}^{k-1}) \Pr\{r_k = l | \mathbf{Z}^{k-1}\}} \\ &= \frac{\Lambda_k^{j-} \mu_{k-1}^j}{\sum_{l=1}^M \Lambda_k^{l-} \mu_{k-1}^l} \end{aligned} \quad (28)$$

式中

$$\Lambda_k^j = N(z_k; H_k^j \hat{x}_{klk-1}^j, S_k^j), \mu_{k-1}^j = \sum_{l=1}^M \pi_{lj} \mu_{k-1}^l \quad (29)$$

步骤4 估计融合

$$\hat{x}_{klk} = \sum_{j=1}^M \mu_k^j \hat{x}_{klk}^j \quad (30)$$

$$P_{klk} = \sum_{j=1}^M \mu_k^j [P_{klk}^j + (\hat{x}_{klk}^j - \hat{x}_{klk})(\hat{x}_{klk}^j - \hat{x}_{klk})^T] \quad (31)$$

需要注意的是由于 STMIE 算法中 $z_k^{\text{Aug}} = z_{k+1}$, 因此估计的状态向量 $\hat{x}_{klk}^{\text{Aug}}$ 取决于 z_{k+1} , 造成了一个采样间隔的延迟; 而基于 CV 模型的滤波器 k 时刻的状态更新值取决于 z_k , 即模型条件滤波中 STMIE 模型是利用 $k+1$ 时刻的量测更新 k 时刻的状态和协方差, 而 CV 模型是利用 k 时刻的量测进行状态和协方差更新. 因此模型似然函数的计算分别利用了 k 时刻和 $k+1$ 时刻的量测, 因而实际上对式(28)的模型概率计算进行了近似处理. 由于量测值为位置信息, 在采样间隔不是太大且目标离传感器较远时, 其相对大小改变较小, 这种近似是合理的.

4 转移概率自适应修正算法

上述 IMM 算法中假定系统模型切换过程是一个 Markov 过程, 即模型跳变服从 Markov 链^[7], 设 Markov 概率转移矩阵为 $\Pi_k = [\pi_{ij}^k]_{M \times M}$, 则:

$$\pi_{ij}^k \triangleq \Pr\{r_k = j | r_{k-1} = i\}, \quad i, j = 1, 2, \dots, M \quad (32)$$

式中: M 为模型的总个数, $r_k = j$ 表示 k 时刻系统匹配的模型为 j 模型, π_{ij}^k 表示模型 i 转移到模型 j 的概率, 且对于任意 $i \in \{1, 2, \dots, M\}$ 有 $\sum_{j=1}^M \pi_{ij}^k = 1$.

标准的 IMM 算法中 Markov 转移概率是预先给定的, 但是由于目标的机动性和先验信息不确定, 这种预先设定的 Markov 矩阵并不能很好的反应目标真实运动模式的切换, 造成估计误差增大^[11]. 因此在滤波过程中需要利用后验信息对 IMM 算法的转移概率进行自适应修正, 使之符合实际情况. 文献[10]和文献[13]分别提出利用模型概率变化的后验信息和利用误差压缩率^[13]的后验信息对模型转移概率进行修正, 而本文提出一种根据模型似然函数值对模型转移概率进行修正的方法.

模型似然函数值中包含了当前的量测信息, 其大小很好的反应了模型与目标真实运动模式匹配程度. 假设 k 时刻子模型 j 的模型似然函数值为 Λ_k^j , 其值相对于其他模型似然函数值越大说明子模型 j 与目标真实运动状态越匹配, 则其他模型向这一匹配模型的转移概率就应越大, 反之, 其他模型转向这一模型概率就应越小, 而本文就是基于这思想对转移概率进行自适应调整. 其具体方法为:

对 Markov 概率转移矩阵的元素利用如下方法进行

修正, 即:

$$\pi_{ij}^{k,0} = \lambda_{ij}^k \pi_{ij}^{k-1} \quad (33)$$

式中: $\lambda_{ij}^k = (\Lambda_k^j / \Lambda_k^i)^\gamma, 0 \leq \gamma \leq 1$ 为调节因子, 控制调节的快慢. 考虑到 k 时刻某一模型转向其他模型的概率总和为 1, 因此需要利用这一性质对式(33)进行修正. 即:

$$\pi_{ij}^{k,1} = \pi_{ij}^{k,0} / \sum_{j=1}^M \pi_{ij}^{k,0} = \lambda_{ij}^k \pi_{ij}^{k-1} / \sum_{j=1}^M \lambda_{ij}^k \pi_{ij}^{k-1} \quad (34)$$

从式(34)可以看到, 若 k 时刻模型 j 的模型似然函数值比模型 i 的大, 即子模型 j 比子模型 i 与目标真实状态更匹配, 通过修正后由模型 i 转移到模型 j 的概率也随之增大, 因而在下一时刻滤波前的模型交互中, 模型似然函数值大的子模型在交互估计输出中所占的比重更大; 相反, 若 k 时刻模型 j 的模型似然函数值比模型 i 的小, 通过修正后由模型 i 转移到模型 j 的概率也随之减小, 模型似然函数值小的子模型在交互估计输出中所占的比重减小. 通过这种利用量测信息实时自适应地修正模型转移概率的方法, 增强了匹配模型的作用, 压缩了非匹配模型的影响.

但是式(34)的转移概率设计仍存在不足, 可能导致矩阵主对角元素的某些值越来越大, 而某些值会越来越小, 即匹配模型转移到自身的概率会越来越大, 而不匹配模型转移到自身的概率会越来越小. 但当目标机动使得不匹配模型变成匹配模型时, 会导致当前匹配模型转移到之前的匹配模型的概率仍很大, 转移到自身的概率仍较小, 造成模型切换比较缓慢. 鉴于此, 对式(34)做如下调整, 在自适应调整转移概率的同时保持 Markov 矩阵的主对角占优. 对 Markov 矩阵的主对角线元素设定一个阈值 Th , 若主对角线元素 $\pi_{ii}^{k,1} < \text{Th}$ ($0 < \text{Th} < 1$), 则对其所在行的元素作如下修改:

$$\pi_{ii}^k = \text{Th}, \pi_{ij}^k = \pi_{ij}^{k,1} - (\text{Th} - \pi_{ii}^{k,1}) \pi_{ij}^{k,1} / (\sum_{j=1}^M \pi_{ij}^{k,1} - \pi_{ii}^{k,1}) \quad (35)$$

若 $\pi_{ii}^{k,1} \geq \text{Th}$, 则其所在行的元素保持不变. 显然, 经过修正后仍满足 $0 \leq \pi_{ij}^k \leq 1$ 且 $\sum_{j=1}^M \pi_{ij}^k = 1$ 的要求. 同时经过式(34)、(35)修正, 模型切换过程中不仅能更多地利用匹配模型的信息, 削弱非匹配模型的影响, 而且能增强算法的稳定性, 使跟踪精度和收敛速度都得到提高.

图1为提出的自适应转移概率 IMM-STMIECV 算法流程图.

5 仿真校验

从两个方面来验证本文提出算法的性能, 首先验证本文提出的转移概率自适应算法的性能, 然后验证本文提出模型集设计方法性能的好坏.




图1 自适应转移概率IMM-STMIIECV算法

5.1 转移概率自适应修正算法性能分析

选择文献[6]中的机动场景3来测试本文提出的自适应转移概率算法的性能,并同时与标准的IMM算法、文献[10]提出的依据模型概率的变化修正转移概率以及文献[13]提出的根据误差压缩率修正转移概率的方法进行对比分析。目标从 $x_0 = [8000, 600, 8000, 600]$ (m, m/s, m, m/s) 出发,并在开始的20s匀速运动。接下来,目标在21~110s内进行协同转弯运动,转弯速率为 $1/30$ (rad/s)。在此之后,目标保持匀速直线运动50s直至运动结束。此处目标只有两种运动模式,即匀速运动和协同转弯运动。为了测试这4种算法的性能,同时考虑到需要比较模型切换速度以及模型概率估计,所有算法都采用匹配模型集,即所有IMM算法都采用CV模型和转弯角速度已知 ($\omega = 1/30$ (rad/s)) 的CT模型作为IMM算法的模型集。CV、CT模型过程噪声协方差矩阵为 $Q^{CV} = \Gamma^{CV} \text{diag}(q_{cv1}, q_{cv2}) (\Gamma^{CV})^T, Q^{CT} = \Gamma^{CT} \text{diag}(q_{ct1}, q_{ct2}) (\Gamma^{CT})^T$ 其中:

$$\Gamma^{CV} = \Gamma^{CT} = \begin{bmatrix} T^2/2 & T & 0 & 0 \\ 0 & 0 & T^2/2 \end{bmatrix}^T \quad (36)$$


$q_{cv1} = q_{cv2} = q_{ct1} = q_{ct2} = 0.01 \text{ m}^2 \cdot \text{s}^{-4}$ 。本文算法的调节因子 $\gamma = 1/2$, Markov 概率转移矩阵主对角线元素的阈值 $\text{Th} = 0.7$ 。4种算法的初始 Markov 概率转移矩阵及模型初始概率为:

$$\Pi_0 = \begin{bmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{bmatrix}, u_0 = \begin{bmatrix} 0.5 \\ 0.5 \end{bmatrix} \quad (37)$$

量测为线性量测,即 $z_k = [x_k \ y_k]^T$,量测协方差矩阵为 $R = \text{diag}(100^2, 100^2)$,采样间隔 $T = 1\text{s}$ 。采用两点初始化^[18]的方法, Monte Carlo 仿真实验100次。图2为4种方法的均方根误差(RMSE)曲线,图3给出了单次实验中各算法的模型概率变化曲线。

仿真结果表明,3种时变转移概率算法的跟踪性相比标准的IMM算法都用不同程度的提升。但相对来说,本文方法拥有更好的跟踪性能,具体表现在:

(1) 拥有更高的跟踪精度,从图2可以看到,无论



(a) 位置均方根误差




图2 均方根误差对比分析

是位置均方根误差还是速度均方根,本文方法的稳态误差都是最小的,跟踪精度较标准的IMM算法有大幅度提升,且好于文献[10]和文献[13]方法。

(2) 模型切换更迅速,收敛速度更快,模型概率估计更加准确。本文方法完成模型切换所用的时间平均只有7s左右,标准的IMM算法和文献[10]方法需要15s左右的时间才能完成模型切换,而文献[13]方法需要30s左右的时间才能实现从一个模型到另一个模型的过渡。在模型概率估计方面,本文方法拥有绝对的优势,远好于其他三种方法,除最开始10s左右滤波器在调整导致模型概率估计不太准确外,其他时间模型概率变化与目标真实的模式的变化十分接近,说明算法增强了匹配模型的作用,削弱了非匹配模型的影响。

本文方法的缺陷在于峰值误差(最大误差)较大,尤其是当目标转弯运动变为匀速运动时,误差增大明显。原因在于本文提出的自适应转移概率IMM算法极大的削弱了非匹配模型的作用,但当目标机动非匹配模型变成匹配模型时,模型切换有一定时间的滞后,导致模型切换过程中误差较大。

5.2 本文算法模型集设计性能分析

上述实验为已知目标真实运动模式的情况下采用匹配模型集验证本文提出的自适应转移概率方法对标准的IMM算法性能的提高。但是现实情况中,目标的机动类型,机动强度以及何时机动都是未知的,因而IMM算法存在模型集设计的难题。但目标可能的




图3 模型概率变化

运动模式概括起来又是已知的,即主要有匀速运动,匀加速运动,以及转弯运动.因而传统的 IMM 算法采用 CV、CA 模型的组合或 CV、CA、CT 模型的组合实现对机动目标跟踪,利用相关噪声模型与 CV 模型的组合也比较常见.但是由于目标的机动程度未知,上述几种方法的性能通常不太理想,为此本文提出一种新颖的模型集设计方法,下面对本文提出模型集设计的性能进行验证.选取了包含三种运动模式的目标连续机动的运动场景,用本文提出的 IMM-STMIECV 算法、IMM-CVCA 算法、IMM-CVCACT 算法以及 IMM-CVCS 算法分别对目标进行跟踪,并以均方根误差为性能评价指标.需要指出的是,这里的 CT 模型是转弯角速度未知的转弯模型,其状态方程是非线性的,利用扩展卡尔曼滤波(Extended Kalman Filter, EKF)算法进行滤波.

假设目标初始状态 $\mathbf{x}_0 = [10000, -160, 2000, 50]^T$ (m, m/s, m, m/s), 在二维平面内运动 120s. 分别在 0 ~ 20s, 40 ~ 60s, 110 ~ 120s 进行匀速运动, 20 ~ 40s 和 60 ~ 80s 进行匀速转弯运动, 80 ~ 110s 进行匀加速运动, 20 ~ 40s, 60 ~ 80s 时角速度分别为 $\pi/18$ (rad/s) 和 $-\pi/20$ (rad/s), 80 ~ 110s 时两个方向的加速度分别为 $5\text{m/s}^2, 5\text{m/s}^2$. 图 4 为目标运动的真实航迹图.

各算法的参数设置如下:

CV 模型的噪声协方差与 4.1 节相同, CA 模型的过




图4 目标真实航迹

程噪声协方差为 $\mathbf{Q}^{\text{CA}} = \mathbf{I}^{\text{CA}} \text{diag}(q_{ca1}, q_{ca2}) (\mathbf{I}^{\text{CA}})^T$, CT 模型的过程噪声协方差为 $\mathbf{Q}^{\text{CT}} = \mathbf{I}^{\text{CT}} \text{diag}(q_{ct1}, q_{ct2}, q_{ct3}) (\mathbf{I}^{\text{CT}})^T$, 式中:

$$\mathbf{I}^{\text{CA}} = \begin{bmatrix} T^2/2 & T & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & T^2/2 & T & 1 \end{bmatrix}^T, \quad (38)$$

$$\mathbf{I}^{\text{CT}} = \begin{bmatrix} T^2/2 & T & 0 & 0 & 0 \\ 0 & 0 & T^2/2 & T & 0 \\ 0 & 0 & 0 & 0 & T \end{bmatrix}^T$$

$q_{ca1} = q_{ca2} = 10\text{m}^2 \cdot \text{s}^{-4}$; $q_{ct1} = q_{ct2} = 0.01\text{m}^2 \cdot \text{s}^{-4}$, $q_{ct3} = 0.001\text{rad}^2 \cdot \text{s}^{-4}$; STMIE 中 $\mathbf{w}_k$ 的方差为 $E(\mathbf{w}_k \mathbf{w}_k^T) = \text{diag}(1, 1)$, 预先选定的常数 $\alpha_i = 1$, 弱化因子 $\eta = 1$. 同时为了比较的公平性, 4 种 IMM 算法都采用本文提出

的自适应转移概率方法. IMM-STMIECV、IMM-CVCA、IMM-CVCS 的模型初始概率都为 $[0.5, 0.5]^T$, IMM-CVCACT 算法模型初始概率为 $[1/3, 1/3, 1/3]^T$. 4 中算法的初始 Markov 概率转移矩阵分别为:

$$\begin{aligned} \Pi_{1,0} = \Pi_{2,0} = \Pi_{4,0} &= \begin{bmatrix} 0.95 & 0.05 \\ 0.05 & 0.95 \end{bmatrix}, \\ \Pi_{3,0} &= \begin{bmatrix} 0.9 & 0.05 & 0.05 \\ 0.05 & 0.9 & 0.05 \\ 0.05 & 0.05 & 0.9 \end{bmatrix} \end{aligned} \quad (39)$$

自适应转移概率算法的调节因子 $\gamma = 1/3$, Markov 概率转移矩阵主对角线元素的阈值 $\text{Th} = 0.7$. 量测为线性量测, 即 $z_k = [x_k \ y_k]^T$, 量测协方差矩阵为 $R = \text{diag}(100^2, 100^2)$, 采样间隔 $T = 1\text{s}$. 采用三点初始化^[18]方法, Monte Carlo 实验 200 次. 图 5 分别显示的是这四种算法的位置和速度均方根误差曲线, 同时对各算法观测时间内平均均方根误差, 峰值误差 (20s 以后) 等进行了统计, 结果如表 1 所示.

表 1 算法跟踪性能比较

算法类型	观测时间内估计平均误差		观测时间内估计峰值误差	
	位置 / m	速度 / (m · s ⁻¹)	位置 / m	速度 / (m · s ⁻¹)
IMM-STMIECV	82.83	41.37	139.85	94.45
IMM-CVCA	109.11	54.63	196.41	113.62
IMM-CVCACT	96.16	38.86	144.90	88.42
IMM-CVCS	101.01	46.91	179.89	109.07

表 1 统计的结果表明, 本文算法的平均位置均方根误差和位置峰值误差都最小, 而平均速度均方根误差和速度峰值误差和 IMM-CVCACT 算法相当, 但小于 IMM-CVCA 算法以及 IMM-CVCS 算法. 从图 5 可以看到, 无论目标在哪种运动模式, 本文算法的位置均方根误差几乎都是这几种算法中最小的, 而速度均方根误差只有在目标转弯机动时稍大于 IMM-CVCACT 算法, 说明采用 STMIE 模型和 CV 模型的组合的 IMM 算法具有良好的适应性, 能实现对目标的全面自适应跟踪, 跟踪精度较传统的模型集设计方法得到了显著的提高. 而在收敛速度方面, 虽然当目标机动时, 本文方法的跟踪误差也明显增大, 但能迅速收敛, 误差保持在一个较小的值, 而其他方法收敛速度相对较慢, 且目标机动时跟踪精度低. 另外, 采用 STMIE 模型和 CV 模型组合的设计, 在量测误差相同但机动性更强的条件下, 算法的峰值误差较 4.1 节得到了改善, 原因在于 STMIE 也能实现对匀速目标的跟踪, 而转弯角速度已知的 CT 模型不能实现对匀速目标的跟踪.

综上, 本文提出的自适应转移概率 IMM-STMIECV 算法由于采用新颖的模型集设计同时依据量测信息实




图 5 均方根误差对比分析

时修正转移概率, 算法能实现对目标全面的自适应跟踪, 无论目标是否机动, 相比其他三种算法跟踪精度更高, 模型切换迅速, 收敛速度快, 同时只采用两个跟踪模型, 算法复杂度相对较低. 算法的跟踪性能较传统方法有较大的提高, 是一种性能较为优越的机动目标跟踪算法.

6 结论

本文针对机动目标跟踪问题, 在分析标准 IMM 算法存在的不足的基础上, 提出一种自适应转移概率的交互式多模型算法. 仿真结果表明采用 STMIE 模型和 CV 模型的组合, 能提高 IMM 算法的适应性, 无论目标是否机动以及机动程度如何, 在无目标任何先验信息的条件下相对其他通用型跟踪算法拥有更高的跟踪精度. 采用自适应转移概率算法, 能根据量测信息实时对转移概率进行修正, 增强匹配模型的作用, 削弱非匹配模型的影响, 使模型切换更迅速更合理, 对模型概率的估计更加准确, 收敛速度更快, 算法的跟踪精度得到了显著的提高.

参考文献

- [1] Xu L, Li X R, Duan Z. Hybrid grid multiple-model estimation with application to maneuvering target tracking [J]. IEEE Transactions on Aerospace and Electronic Systems, 2016, 52(1): 122–136.

- [2] Sithiravel R, McDonald M, Balaji B, et al. Multiple model spline probability hypothesis density filter[J]. IEEE Transactions on Aerospace and Electronic Systems, 2016, 52(3): 1210 – 1226.
- [3] Nemeth C, Fearnhead P, Mihaylova L. Sequential monte carlo methods for state and parameter estimation in abruptly changing environments[J]. IEEE Transactions on Signal Processing, 2014, 62(5): 1245 – 1255.
- [4] Khaloozadeh H, Karsaz A. Modified input estimation technique for tracking maneuvering targets[J]. IET Radar Sonar Navigation, 2009, 3(1): 30 – 41.
- [5] 杨金龙, 姬红兵, 樊振华. 强跟踪输入估计概率假设密度多机动目标跟踪算法[J]. 控制理论与应用, 2011, 28(8): 1164 – 1170.
Yang Jin-long, Ji Hong-bing, Fan Zhen-hua. Strong tracking modified input estimation probability hypothesis density for multiple maneuvering targets tracking [J]. Journal of Control Theory and Applications, 2011, 28(8): 1164 – 1170. (in Chinese)
- [6] Lan J, Li X R, Mu C. Best model augmentation for variable-structure multiple-model estimation[J]. Aerospace and Electronic Systems, IEEE Transactions on, 2011, 47(3): 2008 – 2025.
- [7] Li W, Jia Y. An information theoretic approach to interacting multiple model estimation[J]. IEEE Transactions on Aerospace and Electronic Systems, 2015, 51(3): 1811 – 1825.
- [8] 刘先省, 胡振涛, 金勇, 等. 基于粒子优化的多模型粒子滤波算法[J]. 电子学报, 2010, 38(2): 301 – 306.
Liu Xian-xing, Hu Zhen-tao, Jin Yong, et al. A novel multiple model particle filter algorithm based on particle optimization[J]. Acta Electronica Sinica, 2010, 38(2): 301 – 306. (in Chinese)
- [9] 万九卿, 梁旭, 马志峰. 基于自适应观测模型交互多模型粒子滤波的红外机动目标跟踪[J]. 电子学报, 2011, 39(3): 602 – 608.
Wan Jiu-qing, Liang Xu, Ma Zhi-feng. Infrared maneuvering target tracking based on IMM-PF with adaptive observation model [J]. Acta Electronica Sinica, 2011, 39(3): 602 – 608. (in Chinese)
- [10] 郭志, 董春云, 蔡远利, 等. 时变转移概率 IMM-SRCKF 机动目标跟踪算法[J]. 系统工程与电子技术, 2015(1): 24 – 30.
Guo Zhi, Dong Chun-yun, Cai Yuan-li, et al. Time-varying transition probability based IMM-SRCKF algorithm for maneuvering target tracking [J]. Journal of Systems Engineering and Electronics, 2015(1): 24 – 30. (in Chinese)
- [11] Wang G. ML Estimation of transition probabilities in jump markov systems via convex optimization[J]. IEEE Transactions on Aerospace and Electronic Systems, 2010, 46(3): 1492 – 1502.
- [12] Guo R, Shen M, Huang D, et al. Recursive estimation of transition probabilities for jump Markov linear systems under minimum Kullback-Leibler divergence criterion [J]. Iet Control Theory & Applications, 2015, 9(17): 2491 – 2499.
- [13] 臧荣春, 崔平远. 马尔可夫参数自适应 IFIMM 算法研究[J]. 电子学报, 2006, 34(3): 521 – 524.
Zang Rong-chun, Cui Ping-yuan. Research on adaptive markov parameter IFIMM algorithm [J]. Acta Electronica Sinica, 2006, 34(3): 521 – 524. (in Chinese)
- [14] Yuan T, Bar-Shalom Y, Willett P, et al. A multiple IMM estimation approach with unbiased mixing for thrusting projectiles[J]. IEEE Transactions on Aerospace Electronic Systems, 2012, 48(4): 3250 – 3267.
- [15] Zhu L, Cheng X. High manoeuvre target tracking in coordinated turns [J]. IET Radar Sonar Navigation, 2015, 9(8): 1078 – 1087.
- [16] Blackman S S, Popoli R. Design and Analysis of Modern Tracking Systems [M]. Boston: Artech House, 1999. 224 – 240.
- [17] Farrell W. Interacting multiple model filter for tactical ballistic missile tracking [J]. IEEE Transactions on Aerospace and Electronic Systems, 2008, 44(2): 418 – 426.
- [18] 何友, 修建娟, 关欣, 等. 雷达数据处理及应用(第三版) [M]. 北京: 电子工业出版社, 2013. 44 – 47.

作者简介



许登荣 男, 1991 年 4 月出生于湖南邵阳. 硕士, 现为 93046 部队的助理工程师, 主要研究方向为雷达数据处理.
E-mail: xudengrong@126.com



程水英 男, 1974 年 11 月出生于安徽舒城, 博士, 现为电子工程学院副教授. 主要研究方向有机动目标跟踪、非线性滤波、软件无线电、DSP 及应用等.
E-mail: csyebx@163.com

包守亮 男, 1993 年 5 月出生于四川达州. 现为电子工程学院硕士研究生. 主要研究方向为雷达数据处理.
E-mail: 15656036629@163.com