

doi:10.11835/j.issn.1674-4764.2013.S2.043

基于 IMM 的舰载雷达目标跟踪算法研究

刘 炬

(中国国际航空股份有限公司运行控制中心西南分控中心飞行签派,成都 610202)

摘 要:首先研究了目标跟踪中的卡尔曼滤波算法和常用的机动目标跟踪模型,分析了各模型基于卡尔曼滤波算法的跟踪性能。然后,引入交互式多模型算法,使用多个不同的运动模型匹配目标不同的运动模式,且各模型之间存在交互。在 MATLAB 中模拟舰载雷达的目标运动航迹,采用交互式多模型算法,通过对经典交互式模型(即一个 CV 模型和一个 CA 模型)的实验仿真,验证了在目标跟踪系统中交互式多模型算法的有效性。

关键词:机动目标跟踪;交互式多模型;目标跟踪模型;舰载雷达

中图分类号:V243 **文献标志码:**A **文章编号:**1674-4764(2013)S2-0164-06

IMM-Based Ship-Borne Radar Target Tracking Algorithm

Liu Ju

(Southwest Sub-control Center, Operation Control Center, Air China Limited, Chengdu 610202)

Abstract: The Kalman filtering algorithm and commonly used maneuvering target tracking models in the target tracking are firstly studied in this paper, tracking performances of all models based on the Kalman filtering algorithm are simulated and analyzed. Then, multiple model target tracking algorithm is analyzed and studied, which uses multiple motion models to match different target motion models and exists interacting between all models. In this paper, the target tracking of shipboard radar is simulated with MATLAB. It shows the feasibility of the interacting multiple model algorithm composed of a CV model and a CA model. The simulation results indicate, this algorithm obtains a better performance in tracking high speed and high maneuvering targets and a better balance between the performance and computational complexity, as well as very practicability, which is suitable for the tracking target of shipboard radar tracking target.

Key words: maneuvering target tracking; interacting multiple model; target tracking model; shipboard radar

在目标跟踪领域,研究人员对于目标不同的运动状态,提出了很多有效的目标跟踪算法,这些算法可以在目标模型做固定不变的运动时,起到很好的跟踪作用。但是若目标处于机动且多运动模型情况下,这些算法的跟踪精度就有误差。于是,布拉姆(Blom)和巴沙洛姆(Barshalom)提出了一种具有马尔可夫切换系数的交互式模型 IMM 算法,该模型包括了多种模型,目标状态估计是由多个滤波器共同作用得出的。算法可不进行机动检测,能同时达到全面自适应的能力。本文把在空域中机动的目标作为研究对象,采用交互式多模型算法进行跟踪,在跟踪时采用多个模型(如蛇形运动,变加速运动等模型)描述机动目标的运动方式,来提高目标的跟踪精度。

1 常用模型

1.1 Singer 模型

Singer 模型是假设目标行为中其加速度服从零均值、平稳的一阶时间分布。依据 Singer 模型的特性,我们设其加速度随时间的相关函数为指数衰减,其表达式为:

$$R_a(\tau) = E\{a(t), a(t+\tau)\} = \delta_a^2 \cdot e^{-a|\tau|} \quad (1)$$

式(1)中, δ_a^2 、 a 是区间 $(t, t+\tau)$ 内目标机动特性的决定性参数,其中 δ_a^2 为加速度的方差; a 为机动时间的倒数,即机动频率。机动频率的确切值一般需要实际测量确定。

假设机动加速度的均值为零,且其概率密度函数近似服从均匀分布,即

$$\dot{a} = -a \cdot a(t) + \omega(t) \quad (2)$$

式中, $\omega(t)$ 的均值为零;方差为 $2a \cdot \delta_a^2$ 的高斯噪声。最后,当 $m=1, n=2$ 时机动目标模型变为下述一阶时间相关模型,即 Singer 模型:

$$\begin{bmatrix} \dot{x}(t) \\ \dot{\dot{x}}(t) \\ \ddot{x}(t) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} x(t) \\ \dot{x}(t) \\ \ddot{x}(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \omega(t) \quad (3)$$

Singer 模型的离散形式如下:

$$\begin{bmatrix} X(k+1) \\ \dot{X}(k+1) \\ \ddot{X}(k+1) \end{bmatrix} = \Phi(k+1, k) \begin{bmatrix} X(k) \\ \dot{X}(k) \\ \ddot{X}(k) \end{bmatrix} + F(k)W(k) \quad (4)$$

其中

收稿日期:2013-09-30

作者简介:刘炬(1987-),男,助理工程师,主要从事计算机科学与技术研究,(E-mail)zhangxulikeyou@126.com。

$$\Phi(k+1, k) = \begin{bmatrix} 1 & T & \frac{1}{a^2}[-1 + aT + e^{-aT}] \\ 0 & 1 & \frac{1}{a}[1 - e^{-aT}] \\ 0 & 0 & e^{-aT} \end{bmatrix} \quad (5)$$

$$F(k) = \begin{bmatrix} \frac{1}{a^2} \left[\frac{1}{a}(1 - e^{-aT}) + \frac{1}{2}aT^2 - T \right] \\ \frac{1}{a} \left[T - \frac{1}{a}(1 - e^{-aT}) \right] \\ \frac{1}{a} [1 - e^{-aT}] \end{bmatrix} \quad (6)$$

从状态转移矩阵来看,当 $a \rightarrow \infty$ 时(即加速度是白噪声过程),则 $\Phi(T, a)$ 简化为

$$\lim_{a \rightarrow \infty} \Phi(T, a) = \lim_{a \rightarrow \infty} \begin{bmatrix} 1 & T & \frac{1}{a^2}[-1 + aT + e^{-aT}] \\ 0 & 1 & \frac{1}{a}[1 - e^{-aT}] \\ 0 & 0 & e^{-aT} \end{bmatrix} = \begin{bmatrix} 1 & T & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \quad (7)$$

此时,状态转移矩阵就是 CV 的状态转移矩阵。

当时 $a \rightarrow 0$, 则 $\Phi(T, a)$ 简化为

$$\lim_{a \rightarrow 0} \Phi(T, a) = \lim_{a \rightarrow 0} \begin{bmatrix} 1 & T & \frac{1}{a^2}[-1 + aT + e^{-aT}] \\ 0 & 1 & \frac{1}{a}[1 - e^{-aT}] \\ 0 & 0 & e^{-aT} \end{bmatrix} = \begin{bmatrix} 1 & T & 0.5T^2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix} \quad (8)$$

1.2 半马尔科夫模型

Singer 模型为零均值模型,这种零均值特性对于模拟目标机动似乎不太合理。为此,摩斯等在 Singer 模型的基础上进行改进,提出了具有随机开关均值的相关高斯噪声模型,该模型把机动看作为相应于半马尔科夫过程描述的一系列有限指令,该指令由马尔科夫过程的转换概率来确定,转移时间为随机变量。半马尔科夫模型为

$$\begin{bmatrix} \dot{X}(t) \\ \ddot{X}(t) \\ \ddot{x}(t) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -\theta & 1 \\ 0 & 0 & a \end{bmatrix} \begin{bmatrix} X(t) \\ \dot{X}(t) \\ \ddot{X}(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} \mu(t) + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \omega(t) \quad (9)$$

式中: θ 为阻力系数; $\mu(t)$ 为确定性输入指令; a 为机动频率; $\omega(t)$ 为高斯噪声。但该模型需要大量预先确定的平均值,因此计算复杂。

1.3 机动目标“当前”模型

机动目标“当前”模型主要考虑的是,当机动目标在当前时刻以某一特定的加速度运动时,其下一时刻的加速度取值范围是有限的,而且必须在“当前加速度”的邻域内。机动目标“当前”模型其本质是一种加速度非零的一阶时间相关模型,其状态空间表达式为:

$$\dot{X}(t) = \bar{a}(t) + a(t) \quad (10)$$

$$\dot{a}(t) = -\alpha \cdot a(t) + \omega(t) \quad (11)$$

式(10)和式(11)中, $\bar{a}(t)$ 在采样周期内假设为常数,表示的是当前时刻加速度的均值。并且有

$$\ddot{x}(t) = -\alpha \cdot \dot{X}(t) + a \cdot \bar{a}(t) + \omega(t) \quad (12)$$

综合式(10)、式(11)和式(12),机动目标“当前”统计模型的表示形式如下:

$$\begin{bmatrix} \dot{X}(t) \\ \dot{X}(t) \\ \ddot{x}(t) \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & -\theta & 1 \\ 0 & 0 & a \end{bmatrix} \begin{bmatrix} X(t) \\ \dot{X}(t) \\ \ddot{X}(t) \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ \alpha \end{bmatrix} \bar{a}(t) + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \omega(t) \quad (13)$$

该模型不同于 singer 模型,其加速度概率密度函数服从瑞利分布,并且在时间轴上符合一阶时间相关过程,具有响应快,跟踪精度高等特点,因此比 singer 模型更符合实际。

1.4 各模型特性总结

由于所假设的随机过程的不同,所以机动目标模型可分为白噪声模型、马尔可夫过程模型和半马尔可夫模型跳变过程模型三类。

其中白噪声模型是将控制输入建模为白噪声,于是我们把白噪声模型可以分为匀速,匀加速和多项式 3 种模型。是一种简单通用的模型,在这里不做介绍,我们只对他的优缺点进行一个对比:

优点:如果模拟机动目标是匀速和匀加速直线运动, CV 模型和 CA 模型能够较好地模拟运动目标的状态,表现在具有较高的跟踪精度。

缺点:目标的加速度向量发生变化时,即目标发生机动的情况,采用匀速 CV 模型和匀加速 CA 模型会有较大的误差,所以要在这种情况下准确描述目标的机动状态则需要采用新的模型。

对比:对于单独的匀速直线运动环境, CV 模型的跟踪性能要比 CA 模型跟踪性能好,但在发生机动的环境里 CA 模型要比 CV 模型具有更好的自适应性,有更好的跟踪性能。

马尔可夫过程模型控制输入建模为 Morkov 过程,包括 Singer 模型及其变形,以及“当前”统计模型等。

Singer 模型:是一阶时间相关模型,只适用于等速和等加速范围内的目标运动。零均值特性对于模拟目标机动似乎不太合理。

机动目标“当前”统计模型:由于采用非零均值和修正瑞利分布表示机动加速度特性,因而比较符合实际。虽然“当前”统计模型对机动目标的跟踪效果较好,但是对非机动或轻微机动目标的跟踪精度不高,并且由于该模型具有固定的加速度均值,限制了其应用范围。

因为目标的运动过程有不确定性,所以目标的整个运动过程很难用单一模型来描述。多模型算法(IMM)是将多个模型算法组成一个模型集,以多个模型模拟不同时刻目标的运动特性,具有对真实系统及外部环境变化的适应性,较高的滤波估计精度和稳定性,因此非常适合于解决目标跟踪问题。

2 交互式多模型算法的原理和特点

布拉姆(Blom)和巴沙洛姆(Barshalom)提出了一种具有

马尔可夫切换系数的交互式模型 IMM 算法,该模型包括了多种模型,目标状态估计是由多个滤波器共同作用得出的。算法可不进行机动检测,能同时达到全面自适应的能力。

IMM 滤波器与非交互 MM 滤波器一样,使用固定的目标模型集合,也就是含有固定结构(Fixed Structure, FS)。对于一个目标,可能存在很多不同的机动方式,一个包含元素数量不多的模型集合,不能完全描述、涵盖这个目标所有可能的机动行为。因此,为使固定结构 MM(Multiple Model, MM)算法达到良好的跟踪性能,就必须使用大量模型及每个模型对应的滤波器。显而易见,使用大量的目标运动模型和滤波器并不合适。首先,会增加计算量;其次,使用大量的目标运动模型和滤波器并不能保证一定会提高跟踪、滤波的性能。所以,一个固定结构的 MM 算法就有一个问题,即模型使用的大小。

一般来说,多模型滤波器包括以下几项内容。

1)模型集的确定。多模型滤波器的性能主要取决于模型的使用数量。应用 MM 估计算法最主要的任务是设计集合 M。一旦集合 M 被确定下来,那么多模型方法所隐含的假定,也就是系统模式,就被 M 的元素按模型的假设表现出来。

2)滤波器的选择。在多模型算法中,会根据模型差异、经典估计、滤波理论以及实际问题需要选择不同的滤波器,如针对跳跃变化的线性系统选择卡尔曼滤波器,针对已知模型的非线性系统选择扩展卡尔曼滤波器或者自适应滤波器,针对复杂环境选择概率数据互联滤波器等。

3)滤波器的初始化。最优多模型估计器计算量按指数规律增加,这是由于假想的数量随时间按几何指数增长。为了减轻计算负荷,很多多模型估计器不得不有效地集中状态的“特殊历史模式”信息,通常反映在单元滤波器在每个周期的输入当中,作为“滤波器重新初始化”。

4)估计融合。总体估计结果是各个基础滤波器的估计结果融合后得到的。

交互式多模型(IMM)算法具有很多优点,如模块化并行结构,跟踪精度高。虽然其计算量会随着模型集中的模型数量 M 的增加呈直线增长,但却以一阶 GPB 的运算量实现了二阶 GPB 的效果。

最初的 GPB(GPB1)估计器使用的 $\bar{x}_{k-1/k-1}^{(i)} = E[x_{k-1} | z^{k-1}] = \hat{x}_{k-1/k-1}$ 和相应的协方差来重新初始化滤波器。也就是说,它利用公共的单一全概率(前一周期的总体估计)作为每个滤波器下一周期的输入。在每个周期,单元滤波器以使用公共输入来进行互联,因为总体估计值包含了所有单元滤波器的信息。GPB1 估计器中,每个单元滤波器在每个周期只运行一次。IMM 估计器可以使用比较灵活的重新初始化方法:

$$\bar{x}_{k-1/k-1}^{(i)} = E[x_{k-1} | z^{k-1}, m_k^{(i)}] = \sum_j \hat{x}_{k-1/k-1}^{(j)} P\{m_k^{(j)} | z^{k-1}, m_k^{(i)}\} \quad (14)$$

IMM 用上式得到的估计和相应的协方差来作为下一周期滤波器的输入。

在 IMM 估计器中,每个滤波器 i 在 k 时刻都有各自的输入 $\bar{x}_{k-1/k-1}^{(i)}$ 和 $\bar{P}_{k-1/k-1}^{(i)}$,这些输入来源于最可能的“类似全概率”,包含所有老的信息, k 时刻模型 i 与真实模式匹配,所有滤波器的输入都是最近一个周期所有滤波器输出估计值的加权和。IMM 估计器中每个滤波器在每个周期也只运行一次,与 GPB1 的重新初始化比较,IMM 的重新初始化方法更加合理、有效。之所以是合理的,是因为当计算 $\hat{x}_{k/k}^{(i)}$ 时,假定 $m_k^{(i)} = \{s_k = m_i\}$ 是真实的;之所以是有效的,是因为 $m_k^{(i)}$ 携带着 s_{k-1} 的变化信息,这信息依次影响 x_{k-1} 。就是这个特别的“调节”使 IMM 重新初始化比 GPB1 算法重新初始化有更高的效率比。

图 1 显示了 IMM 估计器的体系结构,而表 1 列出了一个周期内 IMM 算法的计算过程。

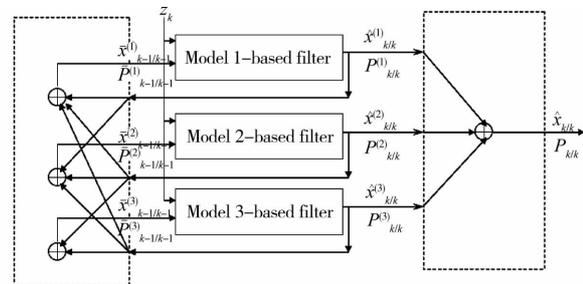


图 1 IMM 估计器体系结构

表 1 IMM 估计器的一个计算周期

IMM 估计器的一个计算周期	
模型条件初始化和重新初始化 ($i = 1, 2, \dots, M$)	预测模式概率: $\hat{\mu}_{k-1/k-1}^{(i)} = P\{m_k^{(i)} z^{k-1}\} = \sum_j \pi_{ji} \mu_{k-1/k-1}^{(j)}$ 混合权重: $\hat{\mu}_{k-1/k-1}^{(i)} = P\{m_k^{(i)} m_k^{(j)}, z^{k-1}\} = \pi_{ji} \mu_{k-1/k-1}^{(j)} / \hat{\mu}_{k-1/k-1}^{(j)}$ 混合估计: $\hat{x}_{k-1/k-1}^{(i)} = E[x_{k-1} m_k^{(i)}, z^{k-1}] = \sum_j \hat{x}_{k-1/k-1}^{(j)} \mu_{k-1/k-1}^{(j)}$ 混合协方差: $\bar{P}_{k-1/k-1}^{(i)} = \sum_j [P_{k-1/k-1}^{(j)} + (\bar{x}_{k-1/k-1}^{(i)} - \hat{x}_{k-1/k-1}^{(j)})(\bar{x}_{k-1/k-1}^{(i)} - \hat{x}_{k-1/k-1}^{(j)})'] \mu_{k-1/k-1}^{(j)}$
模型条件滤波 ($i = 2, 3, \dots, M$)	状态预测: $\hat{x}_{k-1/k-1}^{(i)} = F_{k-1}^{(i)} \bar{x}_{k-1/k-1}^{(i)} + G_{k-1}^{(i)} \omega_{k-1}^{(i)}$ 协方差预测: $P_{k-1/k-1}^{(i)} = F_{k-1}^{(i)} P_{k-1/k-1}^{(i)} (F_{k-1}^{(i)})' + G_{k-1}^{(i)} Q_{k-1}^{(i)} (G_{k-1}^{(i)})'$ 量测残差: $\tilde{z}_{k-1}^{(i)} = z_{k-1} - H_{k-1}^{(i)} \hat{x}_{k-1/k-1}^{(i)} - \bar{v}_{k-1}^{(i)}$ 残差协方差: $S_{k-1}^{(i)} = H_{k-1}^{(i)} P_{k-1/k-1}^{(i)} (H_{k-1}^{(i)})' + R_{k-1}^{(i)}$ 滤波增益: $K_{k-1}^{(i)} = P_{k-1/k-1}^{(i)} (H_{k-1}^{(i)})' - 1$ 状态更新: $\hat{x}_{k-1/k-1}^{(i)} = \hat{x}_{k-1/k-1}^{(i)} + K_{k-1}^{(i)} - \tilde{z}_{k-1}^{(i)}$ 协方差更新: $P_{k-1/k-1}^{(i)} = P_{k-1/k-1}^{(i)} - K_{k-1}^{(i)} S_{k-1}^{(i)} (K_{k-1}^{(i)})'$

续表 1

IMM 估计器的一个计算周期	
模型概率更新 ($i=1,2,\dots,M$)	模型似然: $L_k^{(i)} = p[\tilde{z}_k^{(i)} m_k^{(i)}, z^{k-1}] = \frac{\exp[-(1/2)(\tilde{z}_k^{(i)})'(S_k)^{-1}\tilde{z}_k^{(i)}]}{ 2\pi S_k^{(i)} ^{1/2}}$ 模型概率: $\mu_k^{(i)} = P\{m_k^{(i)} z^k\} = \frac{\mu_{k-1}^{(i)} L_k^{(i)}}{\sum_j \mu_{k-1}^{(j)} L_k^{(j)}}$
估计融合	总体估计: $\hat{x}_{k k} = E[x_k z^k] = \sum_j \hat{x}_{k k}^{(j)} \mu_k^{(j)}$ 总体协方差: $P_{k k} = \sum_j [P_{k k}^{(j)} + (\hat{x}_{k k} - \hat{x}_{k k}^{(j)})(\hat{x}_{k k} - \hat{x}_{k k}^{(j)})'] \mu_k^{(j)}$

多模型方法作为一种混合估计方法,涵盖了固定多模型方法,广义伪贝叶斯方法和交互式多模型方法。其中,交互多模型算法(IMM)比他算法滤波效果好,而且具有计算效费比高、跟踪精度高、跟踪性能好的特点,是研究人员常用的算法。

3 基于交互多模型的目标跟踪算法实现

IMM 算法程序结构

目标跟踪算法涉及到目标系的选择、观测数据预处理、目标运动模型建模、机动检测与机动辨识、滤波与预测等。基于交互多模型的目标跟踪算法实现程序的总框图见图 2。

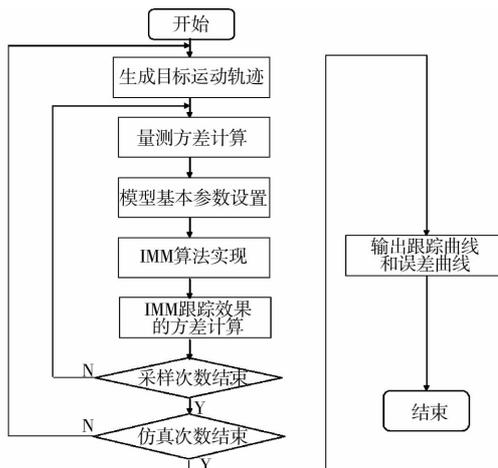


图 2 基于交互式多模型的目标跟踪算法实现流程图

交互多模型算法(IMM)是一种实时更新算法,它利用前一周期目标的估计值计算当前周期目标的跟踪轨迹,其中在一个周期内,IMM 算法包括了模型的输入交互、子模型滤波和预测、模型概率更新和融合输出 4 个步骤。

在 IMM 算法中,模型的输入交互运算是基于给定模型上一时刻的状态、协方差估计基础上,对模型重新进行初始化,包括了预测模式概率初始化、混合权重初始化、混合估计初始化以及混合协方差初始化。模型滤波是根据所初始化的状态及其相应的协方差,对模型进行条件滤波以及状态估计,包括了状态预测、协方差预测、量测残差预测、残差协方差、滤波增益、状态更新、协方差更新。由于卡尔曼滤波器采用的是递推估计技术,便于对实时信号处理,并在非平稳时变信号处理过程中实现时变估计,因此在模型滤波过程中使用的是卡尔曼滤波器。模型概率更新首先需要计算模型似然函数,然后根据似然函数更新模型的概率。融合输出是综合各子模型所计算出的状态估计值、协方差以及模型概

率,求出当前时刻目标状态的总体估计值以及总体协方差。一个周期内,IMM 算法各步具体的计算公式已在表 1 给出。

4 仿真结果与分析

航迹 1: 蛇形运动

初始位移 0 m,初速度 50 m/s,初加速度 0 m²/s²,总时间 200 s。

表 2 航迹 1 的相关参数

时间/s	加速度/(m · s ⁻²)
0~20	0
20~60	10
70~120	0
120~150	-20
150~200	0

对于表 2 所示的航迹 1,其位移跟踪结果如图 3 所示,速度跟踪结果如图 4 所示,加速度跟踪结果如图 5 所示,跟踪误差如图 6 所示。

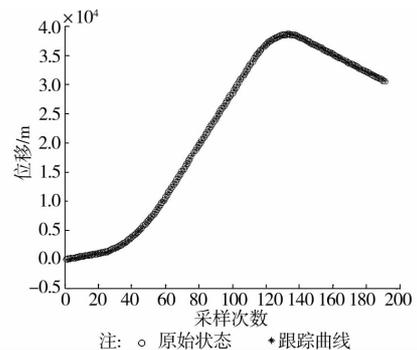


图 3 位移跟踪效果示意图

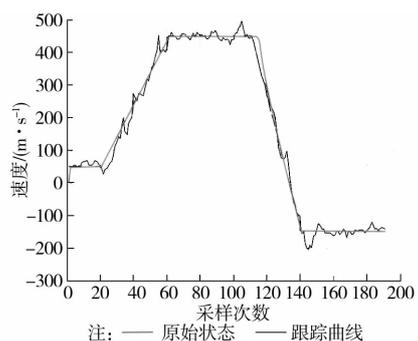


图 4 速度效果跟踪示意图

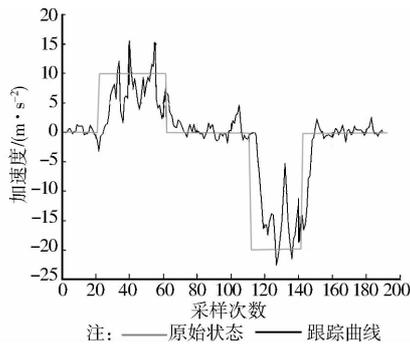


图 5 加速度速度跟踪效果示意图

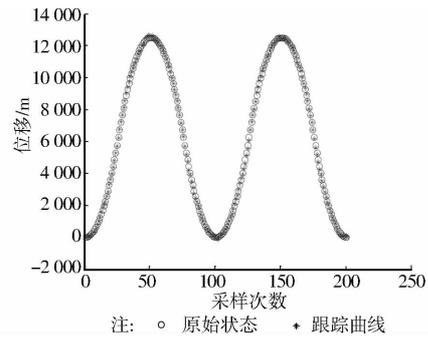


图 7 位移跟踪效果示意图

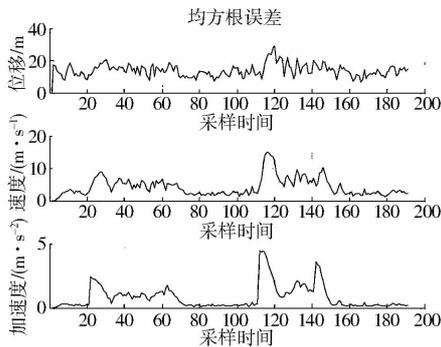


图 6 IMM 跟踪误差效果图

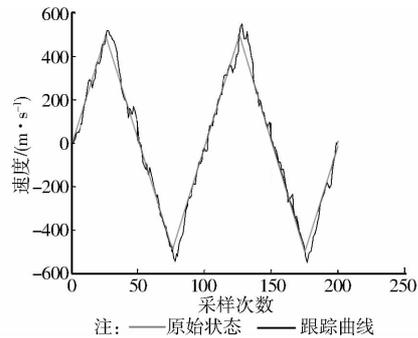


图 8 速度跟踪效果示意图

航迹 1 属于加速度变化相对较频繁的方式, IMM 算法对目标位置的估计均方误差大多在 20 以内, 由于目标位置量达到 10^4 数量级, 这样的误差还是可以接受的, 体现就是目标轨迹与估计图中估计值基本上都很靠近其真实轨迹。目标速度估计的均方误差也大多在 10 以内, 而目标速度最后是达到 500m/s, 所以这个误差也是很小的, 其体现就是运动估计图中速度估计值在真实值附近波动, 波动频率较大, 但幅度较小。目标加速度估计的均方误差都在 5 以内, 由于航迹 1 的目标加速度变化较为频繁, 且加速度不连续, 因此体现在均方误差上, 加速度变化的时刻误差都较大, 然后误差逐渐减小, 但总体来说, 加速度的变化能够使得运动在速度和位移上都能跟踪上目标。综上所述, IMM 算法对于蛇形运动模型也是能达到跟踪精度要求的。

航迹 2: 变加速运动

初始位移 0 m 初速度 0 m/s 初加速度 $20 \text{ m}^2/\text{s}$ 总时间 200 s

表 3 航迹 2 的相关参数

时间/s	加速度/ $(\text{m} \cdot \text{s}^{-1})$
0~25	20
25~75	-20
75~125	20
125~175	-20
175~200	20

对于表 3 所示的航迹 1, 其位移跟踪结果如图 7 所示, 速度跟踪结果如图 8 所示, 加速度跟踪结果如图 9 所示, 跟踪误差如图 10 所示。

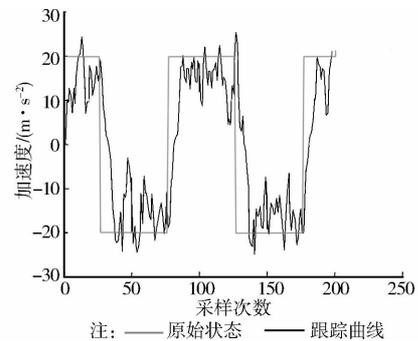


图 9 加速度跟踪效果示意图

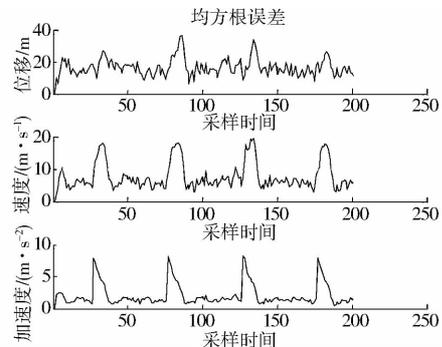


图 10 IMM 跟踪误差效果图

航迹 2 属于变加速度的轨迹运动方式, IMM 算法对目标位置的估计均方误差大多在 20 以内波动, 由于目标位置量达到 10^4 的数量级, 这样的误差可以接受, 体现就是目标轨迹与估计图中估计值基本上都很靠近其真实轨迹。目标速度估计的均方误差大多也是在 10 以内, 而误差加大

的地方都是因为加速度发生突变后产生的,并且目标速度最后达到 10^2 数量级,所以这个误差也是比较小的,其体现就是运动估计图中速度估计值在真实值附近波动,波动频率较大,但幅度较小。目标加速度估计的均方误差都在 5 以内,由于航迹 2 的目标加速度变化较为频繁,且加速度不连续,因此体现在均方误差上,加速度变化的时刻误差都较大,随后误差逐渐减小,但总体来说,加速度的变化能够使运动在速度和位移上都能跟踪上目标。因此,IMM 算法对于变加速运动模型能达到跟踪精度要求。

采用交互式多模型的自适应滤波算法对于匀速—匀加速航迹、匀加速—匀速航迹、蛇形运动航迹以及变加速航迹进行仿真,从仿真结果可以看出,对于 5 个航迹其目标位移的跟踪误差基本上都维持在 20 m 以下,相对于一个 10 的四次方数量级的位移,20 m 的位移误差很小,说明该 IMM 算法很好的保证了跟踪精度。同时,对于 5 个航迹其目标速度的跟踪误差基本上都维持在 10 m/s 以下,同样相对于一个 10 的三次方数量级的速度,10 m/s 的速度误差很小,又由于目标的运动速度是连续变化的,速度的估计值与真实值相近,可以减少目标运动模型改变时带来的额外误差,保证了目标跟踪的性能,提高了模型的全面自适应能力。还有,在 IMM 算法中,有关状态转移概率模型以及滤波器的选择也是影响模型跟踪精度的重要原因。

5 结 论

在对机动目标的跟踪过程中,机动目标的运动轨迹的不确定性,是导致对机动目标跟踪问题复杂的主要原因。笔者主要是对机动目标的跟踪进行讨论与研究,并且重点在于研究舰载雷达跟踪技术,主要运用的算法是交互式多模型算法。

多模型算法是目标跟踪研究中的核心成分,而交互式多模型算法的性价比高,是现在研究范围和应用范围较多的一个方向。针对交互式多模型算法中的模型集设计以及模型概率更新问题进行了系统分析和研究,在给出了目标机动条件下以及量测方程非线性的条件下,在对基于 IMM 算法所设计的目标跟踪方案并进行了仿真实验。

基于目标跟踪技术中的多模型算法研究已很普遍,它不仅具有理论上的意义,更是在实践中有了更大的应用价值。但是研究还有很多值得深入的地方,由于笔者的能力和时间

有限,只是对其匀速匀加速的模型进行了重点分析和深入的仿真研究,所用的模型也是针对于单目标的不同类型所进行的研究,使用的方法和设计理念尚有很多的不足还需要更深入地研究。

参考文献:

- [1] 袁赣南,徐浩鸣,孙枫. 雷达图像与电子海图的实时匹配算法及其计算机实现[J]. 中国航海, 1998(1): 24-26
- [2] 何友. 多传感器信息融合及应用[J]. 北京: 电子工业出版社, 2001.
- [3] 郭治. 现代火控理论[M]. 北京: 国防工业出版社, 1996.
- [4] 宫淑丽,王帮峰,吴红兰,等. 基于 IMM 算法的机场场面运动目标跟踪[J]. 系统工程与电子技术, 2011(10): 2322-2326.
- [5] 陈映,程臻,文树梁. 适用于模型失配时的改进 IMM 算法[J]. 系统工程与电子技术, 2011(12): 2593-2597.
- [6] 江宝安,万群. 基于 UKF-IMM 的双红外机动目标跟踪算法[J]. 系统工程与电子技术, 2008(8): 1454-1459.
- [7] 陈玲,李少洪. 基于无源时差定位系统的机动目标跟踪算法[J]. 系统工程与电子技术, 2005, 27(1): 127-130.
- [8] 杨争斌,郭福成,周一宇. 基于 UT 变换的机动辐射源单站被动跟踪 IMM 算法[J]. 系统工程与电子技术, 2007(1): 5-8.
- [9] 王运锋,刘健波,游志胜,等. 一种简化的交互多模式算法[J]. 系统工程与电子技术, 2005(4): 740-743.
- [10] 郝燕玲,孟凡彬,孙枫,等. 基于 IMM 的 UK-GMPHDF 算法在多机动目标跟踪中的应用[J]. 系统工程理论与实践, 2011(11): 2225-2233.
- [11] 杨飞,巴宏欣,奚和平,等. 一种机动目标跟踪的 IMM 模型优化设计方法[J]. 解放军理工大学学报, 2005, 6(5): 428-431.
- [12] 刘梅,陈锦海,高扬,等. 基于 IMM-CSRFB 的多平台机动目标跟踪方法[J]. 系统工程与电子技术, 2011(1): 1-7.
- [13] 安志忠,王东进. 多站雷达中机动目标高精度跟踪分析[J]. 系统工程与电子技术, 2004(1): 14-17.
- [14] 郭荣华,覃征,李国兵,等. 一种带重采样控制器的 IMM-AUPFB 算法[J]. 清华大学学报: 自然科学版, 2010(4): 539-542.
- [15] 钱华明,陈亮,满国晶,等. 基于当前统计模型的机动目标自适应跟踪算法[J]. 系统工程与电子技术, 2011(10): 2154-2158.
- [16] 蒋宏,宋龙,任章. 非全测状态下的机动目标跟踪[J]. 系统工程与电子技术, 2007(2): 197-200.

(编辑 胡志平)