



DOI:10.12404/j.issn.1671-1815.2309042

引用格式:南奔洋,匡兵,景晖.基于改进自适应交互式多模型无迹卡尔曼滤波算法的车辆目标跟踪[J].科学技术与工程,2025,25(11):4605-4611.

Nan Benyang, Kuang Bing, Jing Hui. Vehicle target tracking based on improved adaptive interacting multiple model-unscented Kalman filter algorithm[J]. Science Technology and Engineering, 2025, 25(11): 4605-4611.

电子技术、通信技术

基于改进自适应交互式多模型无迹卡尔曼滤波算法的车辆目标跟踪

南奔洋, 匡兵*, 景晖

(桂林电子科技大学机电工程学院, 桂林 541004)

摘要 为解决传统交互式多模型(interactive multiple model, IMM)算法在车辆目标跟踪中存在模型概率变化不明显和跟踪精度不足问题,提出一种改进的自适应 IMM-UKF(unscented Kalman filter)算法。首先采用匀速直线、匀加速直线和匀速转弯来建立车辆的运动模型,并通过无迹卡尔曼滤波对车辆目标进行跟踪。然后将子模型概率变化率作为 IMM 算法修正参数,对马尔可夫矩阵主对角线和非主对角线元素采用不同的修正策略。最后设置判定窗修正归一化后的马尔可夫矩阵主对角线元素,以扩大匹配模型的概率。结果表明,改进算法模型概率变化更加明显,位置和速度均方根误差均要小于原有算法,有效地提高了跟踪精度。

关键词 目标跟踪;交互式多模型;自适应;马尔可夫矩阵;无迹卡尔曼滤波

中图分类号 TN953; 文献标志码 A

Vehicle Target Tracking Based on Improved Adaptive Interacting Multiple Model-unscented Kalman Filter Algorithm

NAN Ben-yan, KUANG Bing*, JING Hui

(School of Mechanical and Electrical Engineering, Guilin University of Electronic Technology, Guilin 541004, China)

[Abstract] In order to solve the problems of the traditional interactive multiple model (IMM) algorithm in vehicle target tracking, such as the model probability change is not obvious and the tracking accuracy is insufficient, an improved adaptive IMM-UKF (unscented Kalman filter) algorithm was proposed. Firstly, the vehicle motion model was established by using uniform speed straight line, uniform acceleration straight line and uniform turning, and the vehicle target was tracked by unscented Kalman filter. Then, the probability change rate of sub model was used as the correction parameter of IMM algorithm, and different correction strategies were adopted for the main diagonal and non main diagonal elements of Markov matrix. Finally, the decision window was set to modify the main diagonal element of the normalized Markov matrix to expand the probability of matching model. The results show that the probability of the improved algorithm model changes more obviously, and the root mean square errors of position and velocity are less than the original algorithm, which effectively improves the tracking accuracy.

[Keywords] target tracking; interacting multiple model; adaptive; Markov matrix; unscented Kalman filter

传统的车辆目标跟踪是在考虑特定的车辆运动学模型基础上,借助卡尔曼滤波对车辆轨迹进行预测,这种方法存在一定的局限性,它仅考虑了有限的目标运动模型。实际上在道路上行驶的车辆

往往会出现多种运动情况,如加速、减速和转弯等,采用单一运动模型的方法可能不适用于复杂的运动模式,从而导致所估计的目标状态不够精确。

交互式多模型算法(interacting multiple model,

收稿日期:2023-11-17 修订日期:2024-08-10

基金项目:国家自然科学基金(52262052);广西创新驱动重大专项(桂科 AA22372)

第一作者:南奔洋(2000—),男,汉族,陕西省咸阳市人,硕士研究生。研究方向:多目标跟踪。E-mail:3456235358@qq.com。

*通信作者:匡兵(1972—),男,汉族,湖南耒阳人,硕士,副教授。研究方向:智能驾驶技术,机电产品数字化设计方法,制造业信息化,产品结构拓扑优化设计。E-mail:kuangbing@guet.edu.cn。

投稿网址:www.stae.com.cn

IMM)是一种处理复杂运动模型的滤波算法^[1-3]。该算法的核心思想在于同时使用多个不同的运动模型来跟踪目标,以提高目标跟踪的性能。IMM 算法假设目标的运动可以用多个不同的运动模型来描述,这些子模型涵盖了目标可能的运动模式或轨迹,通过实时观测数据来持续更新各个子模型的权重,随后根据这些权重以及马尔可夫矩阵实现模型间的切换与融合。这一策略使得系统能够更好地适应车辆目标运动模式的变化,从而提供更为精准的估计结果。在 IMM 算法中,所选用的滤波器直接决定了 IMM 算法的性能。为了更好地处理非线性量测模型,本文中选用无迹卡尔曼(unscented Kalman filter, UKF)^[4]作为 IMM 算法的滤波器。标准的 IMM-UKF 算法由于马尔可夫矩阵是固定不变的,不能自适应与目标运动模式进行匹配,导致匹配模型概率不能有效增大,影响了目标跟踪的精度。而自适应交互式多模型(adaptive interacting multiple model, AIMM)算法具备自适应调整概率转移矩阵的特性^[5-9],这一特性帮助克服了传统算法在处理概率模型变化不显著的情况下所遇到的问题,因此在目标跟踪领域 AIMM 算法得到广泛应用并表现出卓越性能。文献[5]利用后验信息中模型概率单调性对马尔可夫矩阵进行修正,加快了匹配模型的切换速度及转换概率,并将其研究用于水下目标的跟踪。文献[6]构建了辅助变量,运用正态伽马混合分布对非高斯量测噪声进行了建模。文献[7-8]考虑量测噪声中存在的异常值,建立了 Student's t 分布量测噪声统计模型,并采用 IMM 实现状态估计,获得了较好的跟踪效果。但是上述算法存在两个主要问题:首先,它们假设系统过程噪声是参数已知的高斯分布,但现实中这些参数往往难以确定;其次,由于传感器故障或信号多路径传播等因素,现有算法的量测噪声模型不能准确捕捉重尾偏斜噪声,缺乏普适性。于是,文献[9]针对噪声污染问题,提出了一种基于新息自适应的扩展卡尔曼滤波雷达目标跟踪算法,通过自适应调节滤波器中的增益矩阵,减少未知噪声对系统的影响。文献[10]针对具有噪声信息和状态模型不确定的动态系统,提出了一种广义交互式多模型自适应滤波算法,通过并行模型处理系统的不确定性,利用 Skew-T 分布和逆威沙特分布解决噪声耦合问题,并采用变分贝叶斯推理递归更新系统状态。文献[11]提出一种依据模型似然函数值之比对马尔可夫矩阵进行实时修正的方法用于增强匹配模型的作用,但是目标机动时,非匹配模型似然概率数值接近于 0,采用该方法有可能会出现奇异现象。文

献[12]在修正参数上进行改进,克服了模型转移概率奇异现象,同时提升了模型切换速度。文献[13]在文献[7,12]的基础上利用判定窗对其进行二次修正,提升模型切换速度和跟踪精度,而且加判定窗的思想可应用于其他改进算法。文献[14]根据 IMM 子模型中连续时间点之间的模型概率比值对马尔可夫矩阵进行修正来提高跟踪精度。文献[11-14]采用比值的方式修正马尔可夫矩阵,当分母接近于零时比值会变得不稳定,导致滤波中断,无法实现目标跟踪。为此,文献[15]提出一种通过子模型概率变化值的自适应修正方法来增加匹配模型的概率,相对于标准 IMM 算法目标跟踪精度更高。

但是由于文献[15]对矩阵每列中所有元素采用相同参数进行修正,没有考虑到主对角线和非主对角线元素性质的不同以及主对角线元素占优的原则,匹配模型概率变化较不明显,影响了跟踪精度的进一步提高。为了提高车辆目标跟踪的性能,本文中采用模型概率变化值修正的思想,在文献[15]的基础上对马尔可夫矩阵主对角线和非主对角线元素采用不同的修正策略,并对归一化后的马尔可夫矩阵每行设定判定窗进行二次修正,兼顾模型切换速度的同时,增大匹配模型的概率,提高目标跟踪的精度。

1 目标模型

IMM-UKF 算法需要建立跟踪目标的模型,是后续数据的预测和模型的交互的基础。因此,下面先简单介绍车辆目标模型。

车辆目标模型可分为运动模型和观测模型。运动模型可以提供有关车辆目标未来位置和速度的信息,这对于 IMM-UKF 预测目标的下一步位置状态非常重要。观测模型可以用来建模观测数据的噪声特性,帮助 UKF 更好地估计目标的状态,并对不确定性进行适当的处理,提高跟踪的鲁棒性。

(1)运动模型。考虑到车辆目标运动特点,本文中 choice 匀速直线(constant velocity, CV)模型、匀加速(constant acceleration, CA)模型和匀速转弯率和速度(constant turn rate and velocity, CTRV)模型来模拟车辆在实际驾驶中的运动情况。车辆目标的状态向量为 $\mathbf{X}(k) = [x, y, v, \theta, w, a]$,其中各元素从左到右表示 k 时刻下目标 xy 坐标、速度、航向角、角速度和加速度信息,车辆状态转移方程为

$$\mathbf{X}(k) = \mathbf{F}\mathbf{X}(k-1) + \boldsymbol{\omega}(k-1) \quad (1)$$

式(1)中: $\mathbf{X}(k)$ 为 k 时刻目标的状态; \mathbf{F} 为状态转移矩阵,表示车辆以某种模式运动时,相邻时刻系统状态变化关系; $\boldsymbol{\omega}(k-1)$ 为 $k-1$ 时刻过程噪声,用于模

拟目标运动过程中的随机扰动和建模过程中的不确定性,服从均值为0 协方差为 \mathbf{Q} 的高斯分布。

(2)观测模型。目标的量测方程为

$$\mathbf{Z}(k) = \mathbf{H}\mathbf{X}(k) + \mathbf{v}(k) \quad (2)$$

式(2)中: \mathbf{H} 为状态观测矩阵,表示车辆的系统状态与观测量之间的关系; $\mathbf{Z}(k)$ 为 k 时刻实际的观测值,包括目标 xy 坐标和航向角; $\mathbf{v}(k)$ 为测量噪声,描述数据采样过程中的测量值存在的偏差,服从均值为0 协方差为 \mathbf{R} 的高斯分布。

2 改进的自适应 IMM-UKF 算法

自适应 IMM-UKF 算法被也称为 AIMM-UKF 算法,它是在标准 IMM-UKF 算法的基础上增加了对马尔可夫矩阵的自适应修正。因此,下面先介绍标准的 IMM-UKF 算法原理,再给出本文中改进的自适应 IMM-UKF 算法的具体实现过程。

2.1 标准 IMM-UKF 算法

标准的 IMM-UKF 算法可分为4个模块,包括输入交互、UKF 滤波、概率模型更新以及融合估计,算法原理如图1所示。IMM 算法是递推进行的,上一时刻 UKF 滤波的结果和更新的模型概率作为输入进行交互,交互后的混合估计和混合协方差输入不同模型下的 UKF 滤波器进行滤波,并通过极大似然函数计算并更新各个模型的概率,最后通过更新后的模型概率融合不同模型下 UKF 滤波器输出的结果得到最终的混合估计。

(1)输入交互。根据 $k-1$ 时刻各个模型的状态估计和模型概率来计算各个 UKF 滤波器输入的交互状态估计。相关公式为

$$c_{k-1}^j = \sum_{i=1}^r \pi_{ji} \mu_{k-1}^i \quad (3)$$

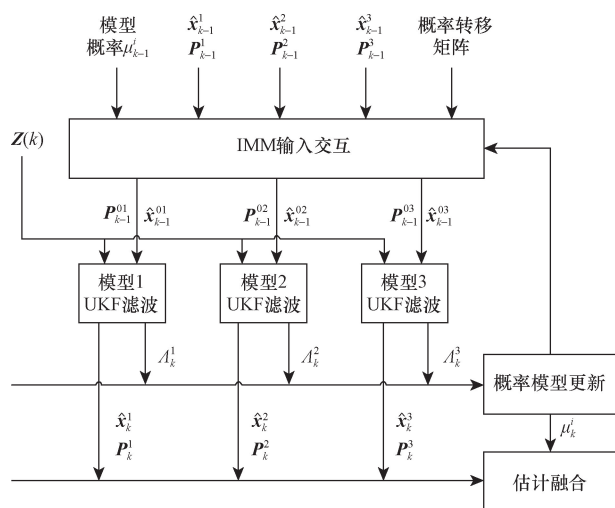


图1 IMM-UKF 算法流程

Fig.1 IMM-UKF algorithm process

$$\mu_{k-1}^{ij} = \frac{1}{c_{k-1}^j} \pi_{ji} \mu_{k-1}^i \quad (4)$$

$$\hat{\mathbf{x}}_{k-1}^{0j} = \sum_{i=1}^r \hat{\mathbf{x}}_{k-1}^i \mu_{k-1}^{ij} \quad (5)$$

$$\mathbf{P}_{k-1}^{0j} = \sum_{i=1}^r \mu_{k-1}^{ij} [\mathbf{P}_{k-1}^i + (\hat{\mathbf{x}}_{k-1}^i - \hat{\mathbf{x}}_{k-1}^{0j}) \times (\hat{\mathbf{x}}_{k-1}^i - \hat{\mathbf{x}}_{k-1}^{0j})^T] \quad (6)$$

式中: c_{k-1}^j 为输入交互后目标处于模型 j 的概率; π_{ji} 为概率转移矩阵中模型 i 转移到模型 j 的概率; μ_{k-1}^i 为交互前模型为 i 的概率; μ_{k-1}^{ij} 为假设目标交互后处于模型 j 的前提下,目标由 i 模型交互的概率;式(5)、式(6)用于计算不同模型下 UKF 滤波器输入的交互状态估计 $\hat{\mathbf{x}}_{k-1}^{0j}$ 和交互协方差 \mathbf{P}_{k-1}^{0j} 。

(2)UKF 滤波。将输入交互阶段得到的交互估计和交互协方差输入多模型的 UKF 滤波器中,结合 k 时刻的观测值 \mathbf{Z}_k 计算各个模型的最优估计 $\hat{\mathbf{x}}_k^j$ 和协方差 \mathbf{P}_k^j 。

(3)模型概率更新。相关公式为

$$\tilde{\mathbf{y}}_k^j = \mathbf{Z}_k - \mathbf{H}\hat{\mathbf{x}}_{klk-1}^j \quad (7)$$

$$\mathbf{S}_k^j = \mathbf{H}\mathbf{P}_{klk-1}^j\mathbf{H}^T + \mathbf{R} \quad (8)$$

$$\Lambda_k^j = \frac{\exp[-(\tilde{\mathbf{y}}_k^j)^T(\mathbf{S}_k^j)^{-1}\tilde{\mathbf{y}}_k^j/2]}{\sqrt{2\pi|\mathbf{S}_k^j|}} \quad (9)$$

$$\mu_k^j = \Lambda_k^j c_{k-1}^j / C_k \quad (10)$$

$$C_k = \sum_{j=1}^r \Lambda_k^j c_{k-1}^j \quad (11)$$

式中: $\tilde{\mathbf{y}}_k^j$ 为各个模型的量测残差,表示实际量测信息 \mathbf{Z}_k 与预测量测信息 $\mathbf{H}\hat{\mathbf{x}}_{klk-1}^j$ 的误差; \mathbf{S}_k^j 为相应的残差协方差矩阵; Λ_k^j 为计算模型 j 的似然概率; μ_k^j 为更新后 k 时刻各个模型的概率。

(4)融合估计。以模型概率 μ_k^j 为权重,将 UKF 滤波器的结果进行加权融合输出总的融合估计 $\hat{\mathbf{x}}_k$ 和协方差 \mathbf{P}_k 。相关公式为

$$\hat{\mathbf{x}}_k = \sum_{j=1}^r \hat{\mathbf{x}}_k^j \mu_k^j \quad (12)$$

$$\mathbf{P}_k = \sum_{j=1}^r \mu_k^j [\mathbf{P}_k^j + (\hat{\mathbf{x}}_k^j - \hat{\mathbf{x}}_k)(\hat{\mathbf{x}}_k^j - \hat{\mathbf{x}}_k)^T] \quad (13)$$

2.2 改进的自适应 IMM-UKF 算法

在交互多模型算法中,马尔可夫矩阵中各个元素表示该元素所处的行和列之间模型的转移概率,体现了各个模型之间的相互作用程度。然而,在标准的 IMM 算法中,马尔可夫概率转移矩阵通常是根

据先验信息或人工选择的固定值进行设定。这种做法在处理机动目标的跟踪问题时可能不够精准。

为了提高机动目标跟踪的准确性,文献[10]提出一种通过子模型概率变化值的方法对马尔可夫矩阵进行修正来增加匹配模型的概率。具体修正方法是首先通过对相邻时刻各个子模型概率的变化值取指数的方式引入修正系数,通过该系数与马尔可夫矩阵对应列元素乘积的方式来调整不匹配模型向匹配模型转移的概率,最后对乘积后的矩阵每行进行归一化来更新马尔可夫矩阵,其在一定程度上提高了 IMM-UKF 算法的精度。但是考虑到其对马尔可夫矩阵每列各个元素使用了相同的修正系数,没有充分考虑到每列中各个元素之间的差异,并且主对角线元素在修正过程可能存在过大或者过小的情况,因此在文献[10]中 AIMM 算法的基础上,重新对概率转移矩阵进行修正,具体实现如下。

假设 $\mu_k(j)$ 代表 k 时刻模型 j 的概率, $\mu_{k-1}(j)$ 代表 $k-1$ 时刻模型 j 的概率。考虑到马尔可夫矩阵各元素值为非负数,而概率差值存在负数,因此通过取指数的方式引入 $\alpha_k(j)$ 来描述模型概率变化情况,表达式为

$$\alpha_k(j) = \exp[\mu_k(j) - \mu_{k-1}(j)] \quad (14)$$

从式(14)可以看出,当概率差值为正数时,变化率 $\alpha_k(j) > 1$,反之 $\alpha_k(j) < 1$,对马尔可夫矩阵中非主对角线元素采用子模型之间概率变化率之比与其乘积进行更新修正,而主对角线元素则采用文献[10]自适应算法进行修正,假设 $\pi_{k-1}(i,j)$ 代表马尔可夫矩阵第 i 行第 j 列元素,修正表达式为

$$\begin{cases} \pi'_{k-1}(i,j) = \frac{\alpha_k(j)}{\alpha_k(i)} \pi_{k-1}(i,j), & i \neq j \\ \pi'_{k-1}(i,j) = \alpha_k(j) \pi_{k-1}(i,j), & i = j \end{cases} \quad (15)$$

考虑到马尔可夫矩阵每行元素之和为 1,故需要对上式进行归一化^[10],表达式为

$$\pi_k(i,j) = \frac{\pi'_{k-1}(i,j)}{\sum_{j=1}^M \pi'_{k-1}(i,j)} \quad (16)$$

考虑到主对角线占优原则,判断归一化后的马尔可夫矩阵每行主对角线元素是否小于阈值 th (取值接近 0.8 为宜),对小于阈值 th 的各行进行二次修正,表达式为

$$\begin{cases} \pi'_k(i,j) = th, & i = j \\ \pi'_k(i,j) = (1 - th) \frac{\pi(i,j)}{1 - \pi(i,i)}, & i \neq j \end{cases} \quad (17)$$

当马尔可夫矩阵对角线元素过大,如果车辆实际运动模型发生转变时,采用子模型之间概率变化

率的修正方法会使匹配模型之间切换存在一定滞后。因此这里再次判断马尔可夫矩阵对角线元素是否大于阈值 th (取值接近 0.95 为宜),对于大于阈值 th 的各行修正方法与上述类似。

3 实验仿真

出于实际应用和计算效率的考虑,将车辆目标的跟踪简化为二维平面上单目标跟踪进行仿真分析。假设车辆先做 10 s 加速度为 1.5 m/s^2 的匀加速直线运动,接下来做 10 s 匀速直线运动,做 10 s 角速度为 0.4 rad/s 的匀速转弯运动,然后最后做 10 s 匀速直线运动。IMM 算法选用 CV、CTRV 和 CA 三个运动学模型,各个模型初始概率均为 $1/3$,初始马尔可夫矩阵为

$$\pi = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0.1 & 0.8 & 0.1 \\ 0.1 & 0.1 & 0.8 \end{bmatrix} \quad (18)$$

结合车辆目标运动情况以及检测算法精度,仿真参数设置如表 1 所示,分别以本文算法、AIMM-UKF 算法、标准 IMM-UKF 算法进行 100 次仿真,通过均方根误差 (root mean square error, RMSE) 和匹配模型的概率来评估跟踪算法的性能。

如图 2 所示为卡尔曼滤波、标准的 IMM-UKF、AIMM-UKF 和本文改进的算法在整个过程中的跟踪轨迹图。可以看出传统卡尔曼滤波算法不能有效

表 1 仿真参数

| 参数 | 名称 | 数值 |
|------|----------|--|
| X | 目标初始状态向量 | (1 000, 1 000, 0, 0.5, 0, 1.5) |
| R | 量测噪声矩阵 | diag(4, 4, 0.09) |
| T | 采样间隔/s | 0.4 |
| th | 修正阈值 | min = 0.8, max = 0.95 |
| Q | 过程噪声矩阵 | diag(0.01, 0.01, 0.01, 0.01, 0.01, 0.01) |

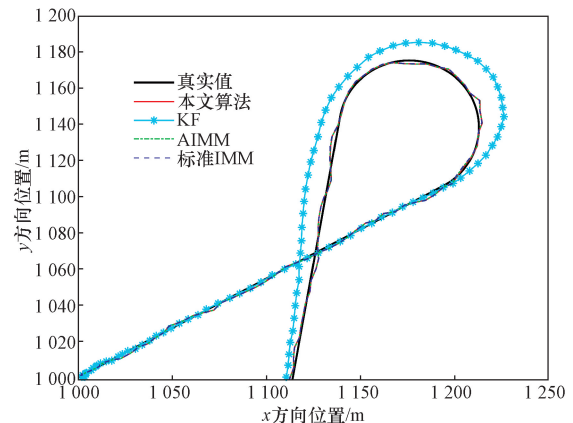


图 2 跟踪轨迹

Fig. 2 Tracking trajectory

处理复杂的运动模型, 初始加速和匀速阶段轨迹比较贴合真实值外, 在匀速转弯过程中传统卡尔曼滤波算法预测结果要偏离的真实值。而其他 3 种 IMM 算法轨迹曲线在不同运动阶段都更贴合与真实值。为了区别 3 中算法的跟踪效果, 如图 3 所示为不同 IMM 算法的位置 RMSE, 大概在第 5 s 后, 本文改进算法对于目标位置估计的误差要低于 AIMM 算法和标准 IMM 算法。

如图 4 所示为 4 种不同算法目标速度估计的变化曲线, 可以看出传统卡尔曼滤波算法估计的目标速度与真实值存在较大的偏差, 而其他三种基于 IMM 的算法对目标速度的估计更贴合真实值。如图 5 所示为不同 IMM 算法的速度 RMSE, 初始时刻速度估计误差变化不大, 随着时间的推移, 本文改进的自适应 IMM-UKF 算法对于目标速度估计的均方根误差要小于标准 IMM 和 AIMM 算法。

如图 6 所示为 3 种 IMM 算法的模型概率变化曲线, 从图中可以发现大部分时间标准的 IMM 算法与目标运动模式匹配的模型概率在 40% ~ 60%, 匹配模型概率变化不明显。文献[10]的 AIMM 算法由

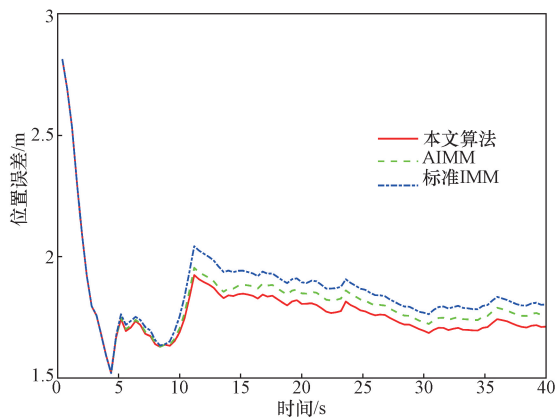


图3 位置均方根误差
Fig. 3 RMSE of position

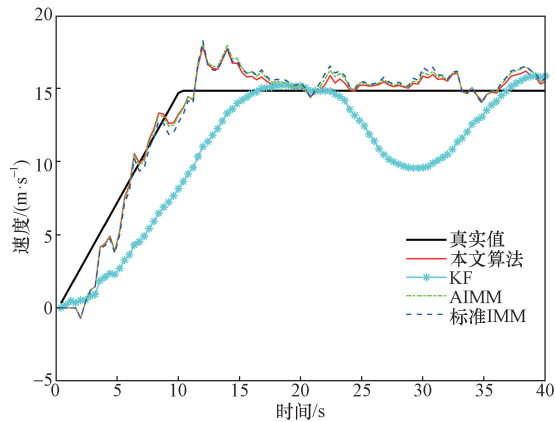


图4 速度估计
Fig. 4 Speed estimation







图5 速度均方根误差
Fig. 5 RMSE of velocity



(a)标准IMM算法



(b)AIMM算法



(c)本文算法

图6 模型概率

Fig. 6 Model probability of three algorithm

于增添了对马尔可夫概率转移矩阵进行自适应修正,除了最后匀速直线段匹配模型概率在 50% 左右,大部分时间概率在 70% 左右,要高于标准 IMM 算法。本文算法在目标处于稳定的运动模式时,匹配模型概率在 80% 左右。目标运动模式切换时,概率曲线交叉点相比于 AIMM 算法也并没有存在滞后,保证了模型切换的速度。

为了防止单次数据的偶然性,如图 7 和图 8 所示为 3 种 IMM 算法 100 次仿真位置和速度均方根误差变化图,本文算法的均方根误差大部分都低于标准 IMM 和 AIMM 算法。如表 2 所示为各算法跟踪性能数据,从表中可以看出本文改进后的算法 RMSE

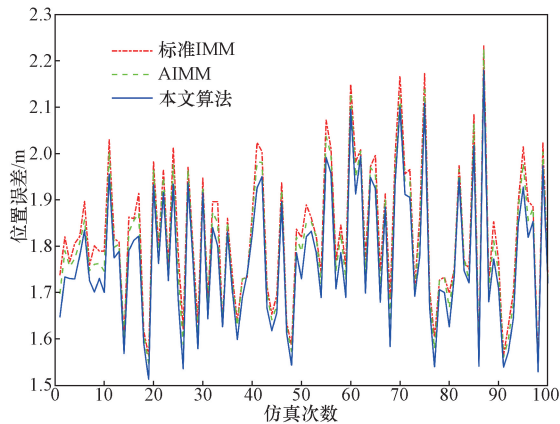


图 7 仿真 100 次的位置均方根误差

Fig. 7 RMSE of position for 100 simulations




图 8 仿真 100 次的速度均方根误差

Fig. 8 RMSE of velocity for 100 simulations

表 2 算法性能数据

Table 2 Algorithm performance data

| 算法 | 平均均方根误差 | | 均方根误差峰值 | |
|------------|---------|---|---------|---|
| | 位置/m | 速度/ ($\text{m}\cdot\text{s}^{-1}$) | 位置/m | 速度/ ($\text{m}\cdot\text{s}^{-1}$) |
| 本文算法 | 1.763 | 0.951 | 2.18 | 1.25 |
| AIMM | 1.793 | 1.021 | 2.225 | 1.339 |
| 标准 IMM-UKF | 1.812 | 1.068 | 2.234 | 1.374 |

结果是最小的。平均位置 RMSE 相比 AIMM 算法和传统算法分别降低了 1.67% 和 2.7%, 平均速度 RMSE 分别降低了 6.9% 和 11%, 证实了改进后的算法在位置估计和速度估计上均比原算法更加精确。

4 结论

本文针对标准的 IMM 算法中存在的模型概率变化不明显导致跟踪精度下降的问题,在文献[10]的 AIMM 算法的基础上,对马尔可夫概率转移矩阵主对角线元素和非主对角线元素提出了不同的修正方法来扩大匹配模型的概率,并通过设置判定窗滤掉主对角线元素过大或过小的值,加快了模型切换的速度,提高目标跟踪过程中的精度。仿真实验结果表明本文算法。

(1) 平均位置均方根误差比 AIMM 算法和标准 IMM 算法分别降低了 1.67% 和 2.7%。

(2) 平均速度均方根误差比 AIMM 算法和标准 IMM 算法分别降低了 6.9% 和 11%。

(3) 当目标处于稳定的运动模型时模型概率在 80% 左右。

参 考 文 献

- [1] Mazor E, Averbuch A, Bar-Shalom Y, et al. Interacting multiple model methods in target tracking: a survey[J]. IEEE Transactions on Aerospace and Electronic Systems, 1998, 34(1): 103-123.
- [2] Kalman R E. A new approach to linear filtering and prediction problems[J]. Journal of Fluids Engineering, 1960, 82(1): 35-45.
- [3] 许红, 谢文冲, 袁华东, 等. 基于自适应的增广状态-交互式多模型的机动目标跟踪算法[J]. 电子与信息学报, 2020, 42(11): 2749-2755.
Xu Hong, Xie Wenchong, Yuan Huadong, et al. Maneuvering target tracking algorithm based on the adaptive augmented state interacting multiple model[J]. Journal of Electronics & Information Technology, 2020, 42(11): 2749-2755.
- [4] Daum F. Nonlinear filters: beyond the Kalman filter[J]. Aerospace and Electronic Systems Magazine, 2005, 20(8): 57-69.
- [5] 王平波, 陈强, 卫红凯, 等. 一种基于模型概率单调性变化的自适应 IMM-UKF 改进算法[J]. 电子与信息学报, 2024, 46(1): 41-48.
Wang Pingbo, Chen Qiang, Wei Hongkai, et al. An improved adaptive IMM-UKF algorithm based on monotonicity of model probability[J]. Journal of Electronics and Information Technology, 2024, 46(1): 41-48.
- [6] Zhang L, Lan J, Li X R. Normal-gamma IMM filter for linear systems with non-Gaussian measurement noise[C]//The 22th International Conference on Information Fusion. Ottawa: IEEE, 2019: 1-8.
- [7] Yun P, Wu P L, He S. An IMM-VB algorithm for hypersonic vehicle tracking with heavy tailed measurement noise[C]//International Conference on Control, Automation and Information Sciences. Han-

- gzhou: IEEE, 2018: 169-174.
- [8] Shen C, Xu D J, Huang W, et al. An interacting multiple model approach for state estimation with non-Gaussian noise using a variational Bayesian method[J]. Asian Journal of Control, 2015, 17(4): 1424-1434.
- [9] 孙铭芳, 吕旭, 赵仁杰, 等. 基于新息自适应的扩展卡尔曼滤波雷达目标跟踪算法[J]. 科学技术与工程, 2023, 23(9): 3738-3743.
- Sun Mingfang, Lü Xu, Zhao Renjie, et al. Extended Kalman filter radar target tracking algorithm based on new interest adaptive[J]. Science Technology and Engineering, 2023, 23(9): 3738 -3743.
- [10] 马天力, 张扬, 高嵩, 等. 具有噪声信息与状态模型不确定系统的 IMM 自适应滤波[J]. 控制与决策, 2024, 39(5): 1604-1611.
- Ma Tianli, Zhang Yang, Gao Song, et al. Interactive multiple model adaptive filter for system with uncertain state model and noise information [J]. Control and Decision, 2024, 39(5): 1604-1611.
- [11] 许登荣, 程水英, 包守亮. 自适应转移概率交互式多模型跟踪算法[J]. 电子学报, 2017, 45(9): 2113-2120.
- Xu Dengrong, Cheng Shuiying, Bao Shouliang. Interacting multiple model algorithm based on adaptive transition probability[J]. Acta Electronica Sinica, 2017, 45(9): 2113-2120.
- [12] 叶瑾, 许枫, 杨娟, 等. 一种改进的时变转移概率 AIMM 跟踪算法[J]. 应用声学, 2020, 39(2): 246-252.
- Ye Jin, Xu Feng, Yang Juan, et al. An improved AIMM tracking algorithm based on adaptive transition probability[J]. Journal of Applied Acoustics, 2020, 39(2): 246-252.
- [13] 王平波, 刘杨. 基于改进自适应 IMM-UKF 算法的水下目标跟踪[J]. 电子与信息学报, 2022, 44(6): 1999-2005.
- Wang Pingbo, Liu Yang. Real-time correction of IMM target tracking algorithm based on probability model [J]. Journal of Electronics & Information Technology, 2022, 44(6): 1999-2005.
- [14] 周非, 罗晓勇, 刘云萍. 基于概率模型的实时修正 IMM 目标跟踪算法[J]. 计算机工程与应用, 2020, 56(21): 85-92.
- Zhou Fei, Luo Xiaoyong, Liu Yunping. Real-time correction of IMM target tracking algorithm based on probability model [J]. Computer Engineering and Applications, 2020, 56(21): 85-92.
- [15] 赵斌, 胡建旺, 吉兵, 等. 修正马尔可夫矩阵的 IMM-GMPHD 算法研究[J]. 军械工程学院学报, 2016, 28(1): 40-45.
- Zhao Bin, Hu Jianwang, Ji Bing, et al. Research on IMM-GMPHD algorithm of modified Markov matrix[J]. Journal of Ordnance Engineering College, 2016, 28(1): 40-45.