

一种时变交互多模型融合目标跟踪方法

栾铸徵, 俞成龙, 顾兵, 赵先涛

(中国船舶重工集团公司第 723 研究所, 江苏 扬州 225101)

摘要: 针对交互多模型(IMM)目标跟踪理论采用不变的马尔可夫转移概率矩阵以及在模型概率更新中采用的是残差模型, 缺乏实时适应性, 提出了以多模型滤波结果为中心, 以贝叶斯估计理论融合多模型跟踪结果来更新目标状态分布, 并根据模型似然函数更新下一时刻模型概率, 以当前滤波模型目标状态分布似然函数来更新模型间马尔可夫转移概率矩阵。采用蒙特卡罗仿真与常规 IMM 方法进行了对比, 对强机动目标和扰动静态目标场景进行了仿真, 结果表明该方法航迹误差精度优于常规 IMM, 可以有效地对机动目标跟踪。

关键词: 马尔可夫转移概率矩阵; 交互多模型(IMM); 似然函数; 贝叶斯估计

中图分类号: TN958; O212.2

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.211555

中文引用格式: 栾铸徵, 俞成龙, 顾兵, 等. 一种时变交互多模型融合目标跟踪方法[J]. 电子技术应用, 2021, 47(9): 111-116.

英文引用格式: Luan Zhuzheng, Yu Chenglong, Gu Bing, et al. A time varying IMM fusion target tracking method[J]. Application of Electronic Technique, 2021, 47(9): 111-116.

A time varying IMM fusion target tracking method

Luan Zhuzheng, Yu Chenglong, Gu Bing, Zhao Xiantao

(The 723 Institute of CSIC, Yangzhou 225101, China)

Abstract: For interacting multiple model (IMM) target tracking theory, the invariable Markov transition probability matrix is used, and the residual model is used in the model probability updating, which is lack of real-time adaptability. In this paper, we propose to update the target state distribution based on the multi model filtering results, Bayesian estimation theory and multi model tracking results, update the model probability at the next moment according to the model likelihood function, and update the Markov transition probability matrix between models with the current filtering model target state distribution likelihood function. The Monte Carlo simulation is compared with the conventional IMM method, and the strong maneuvering target and disturbed static target scenes are simulated. The results show that the track error accuracy of this method is better than that of the conventional IMM method, and it can effectively track the maneuvering target.

Key words: Markov transition probability matrix; interacting multiple model(IMM); likelihood function; Bayesian estimation

0 引言

因为目标受航路、动力及环境等因素影响, 目标总是在做机动运动, 例如反舰导弹末端变轨, 高空制导炸弹抛物线运动时受到空气阻力和重力的作用, 旋翼无人机受人为控制飞停等。这种机动性往往是不可预测的, 使用单一固定的滤波模型很难准确跟踪机动目标状态, 滤波器结果会发散, 导致跟踪失败。因此由 Blom 和 Bar-Shalom 提出交互多模型(IMM)算法, 采用基于位置、匀速、匀加速、Singer 等多种滤波并存方式, 目标状态估计是多个滤波器交互作用的结果, 采用马尔可夫(Markov)链控制模型间的交互, 把各个模型上一时刻的滤波值进行交互作用作为各模型的下一时刻的输入, 然后分别进行滤波, 得到的结果进行模型概率加权输出作为最终的结果, 效果比单模型的好, 从而 IMM 算法广泛

应用到各个领域^[1-4]。但在常规 IMM 中马尔可夫转移概率矩阵是固定值, 并且模型概率是通过卡尔曼滤波(Kalman)更新过程中产生的残差来更新模型概率, 模型概率更新及模型概率转移没有结合当前的目标状态分布。所以本文提出了以模型间似然函数(Likelihood Function)及多模型贝叶斯后验估计(Bayesian Estimation)融合思想, 采用当前模型跟踪结果更新模型交互概率和以贝叶斯估计融合多模型输出作为目标状态更新值, 与目标实际机动情况更加符合, 本文对强机动目标和扰动静态目标进行了基于 Kalman 滤波器的时变 IMM 模型融合算法(TV-IMM)和常规 IMM 方法(C-IMM)仿真, 结果表明时变 IMM 模型融合算法比常规 IMM 方法更有效。

1 时变交互多模型融合理论分析

本方法仍然采用 IMM 处理架构, 时变交互多模型融

合滤波算法原理是同时使用多种滤波器对应多个运动模型,基于贝叶斯后验估计的方法得到目标当前状态的最小均方差估计。首先根据模型概率和模型交互马尔可夫转移概率完成各个模型之间的输入交互作用,结果输入给各个滤波器预测和更新状态,用各个滤波器目标状态分布求解模型间马尔可夫转移概率,同时输入给多模型融合器,根据贝叶斯后验概率估计原理得到目标状态分布更新,再根据似然函数原理更新模型概率,从而完成多模型滤波的闭环跟踪。

与常规 IMM 不同点在于马尔可夫转移概率矩阵计算方法、目标状态分布更新算法、模型概率更新算法上有不同。该滤波器实现流程如图 1 所示,假设有 r 个卡尔曼滤波器模型同时用于目标跟踪,模型间满足相互独立的多维高斯分布特性。TV-IMM 算法可总结为如下 5 步:模型输入相互作用、模型滤波输出、模型输出融合、模型概率更新、模型间转移概率更新。

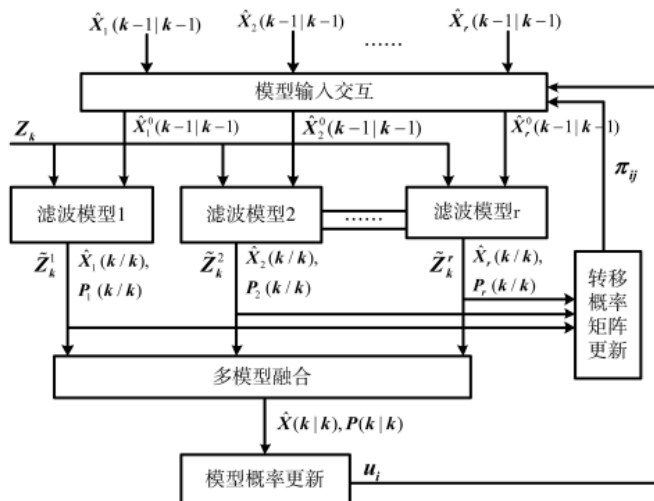


图 1 时变交互多模型融合滤波器结构

1.1 模型输入交互作用^[1-5]

该过程和 IMM 交互多模型一致,就是把各滤波器初始条件混合。利用上一步 $k-1$ 时刻得到的模型概率 $\mu_j(k-1)$ 和马尔可夫(Markov)交互概率矩阵交互作用,产生新的模型交互概率,代表了模型间相互影响的程度。交互概率作用在每一个模型的滤波结果 $\hat{x}_j(k-1|k-1)$, $P_j(k-1|k-1)$, 其中 $j=1, \dots, r$, 得到输入交互, 马尔可夫转移矩阵 π_{ij} 表示:

$$\pi = \begin{bmatrix} \pi_{11} & \pi_{12} & \cdots & \pi_{1r} \\ \pi_{21} & \pi_{22} & \cdots & \pi_{2r} \\ \vdots & \vdots & \ddots & \vdots \\ \pi_{r1} & \pi_{r2} & \cdots & \pi_{rr} \end{bmatrix} \quad (1)$$

Markov 矩阵第 i 行表示第 i 个模型转换为其他模型的概率。第 j 列表示由其他模型转换到第 j 个模型的概率。由于各个模型对目标跟踪影响程度不同,用模型概率 u_i 表示模型 i 的影响程度,则第 i 个模型转化为第 j 个

模型的概率修正为:

$$u_{ij}(0) = u_i \cdot \pi_{ij} \quad (2)$$

可见模型概率 u_i 影响模型交互概率 $u_{ij}(0)$, 模型间转化概率满足概率空间完备性,即第 j 列概率总和为 1:

$$\sum_{i=1}^r u_{ij}(k-1|k-1) = 1 \quad (3)$$

概率空间由修正概率组成,所以模型交互概率由归一化为:

$$\mu_{ij}(k-1|k-1) = u_{ij}(0) / \sum_{m=1}^r u_{mj}(0) \quad (4)$$

第 i 个模型目标状态分布是 $\hat{x}_i(k-1|k-1)$ 和 $P_i(k-1|k-1)$, 则对第 j 个模型输入目标状态交互结果为:

$$x_j^0(k-1|k-1) = \sum_{m=1}^r \hat{x}_m(k-1|k-1) \mu_{mj}(k-1|k-1) \quad (5)$$

第 j 个模型协方差为:

$$P_j^0(k-1|k-1) = \sum_{m=1}^r \mu_{mj}(k-1|k-1) \{P_i(k-1|k-1) + [\hat{x}_i(k-1|k-1) - \hat{x}_j^0(k-1|k-1)][\hat{x}_i(k-1|k-1) - \hat{x}_j^0(k-1|k-1)]^T\} \quad (6)$$

模型输入交互结果为 r 个滤波器提供输入。

1.2 模型滤波输出^[4-6]

滤波器是基于卡尔曼滤波原理,利用观测空间得到的结果更新状态空间的目标信息,是最小均方误差估计,方程如下:

$$\begin{cases} \hat{x}_j(k|k-1) = \phi_j(k) \hat{x}_j(k-1) + W_j(k) \\ Z_j(k) = H_j(k) \hat{x}_j(k) + V_j(k) \end{cases} \quad (7)$$

其中: j 表示第 j 个模型; $x_j(k)$ 是 k 时刻系统状态变量,是 $d_j \times 1$ 维列向量, d_j 为目标状态维数; $Z_j(k)$ 是 k 时刻的系统量测变量,是 $n_j \times 1$ 维列向量, n_j 为观测向量维数; $\phi_j(k)$ 是状态转移矩阵,是 $d_j \times d_j$ 矩阵; $H_j(k)$ 是测量矩阵,是 $n_j \times d_j$ 矩阵; $W_j(k)$ 是高斯型模型白噪声, θ 均值,协方差为 $Q_j(k)$,是 $d_j \times d_j$ 矩阵; $V_j(k)$ 是高斯型量测白噪声, θ 均值,协方差为 $R_j(k)$,是 $n_j \times n_j$ 矩阵。滤波器输入是基于混合初始状态估计 $x_j^0(k-1|k-1)$ 和协方差 $P_j^0(k-1|k-1)$, 应用卡尔曼滤波计算 k 时刻模型 j 的状态估计 $\hat{x}_j(k|k)$ 和协方差 $P_j(k|k)$ 。

状态预测:

$$\begin{cases} \hat{x}_j(k|k-1) = \phi_j \cdot \hat{x}_j^0(k-1) + W_j(k-1) \\ P_j(k|k-1) = \phi_j \cdot P_j^0(k-1|k-1) \cdot \phi_j^T + Q_j(k-1) \end{cases} \quad (8)$$

状态更新:

$$\begin{cases} \hat{x}_j(k|k) = \hat{x}_j(k|k-1) + k_j(k) \cdot v_j(k) \\ P_j(k|k) = P_j(k|k-1) + k_j(k) \cdot S_j(k) + k_j(k)^T \end{cases} \quad (9)$$

其中 $k_j(k)$ 是增益矩阵, $v_j(k)$ 是残差, $S_j(k)$ 是残差协方差矩阵。从而,模型 j 的状态概率分布可以表示为(d_j 为模

型维数):

$$P_j(\mathbf{x}) = N_j(\mathbf{x}; \hat{\mathbf{x}}_j(k|k), P_j(k|k))$$

$$= \frac{1}{(2\pi)^{d/2} \sqrt{|P_j(k|k)|}} e^{-\frac{1}{2}(\mathbf{x} - \hat{\mathbf{x}}_j(k|k))^T P_j(k|k)^{-1} (\mathbf{x} - \hat{\mathbf{x}}_j(k|k))} \quad (10)$$

本步骤完成了各滤波器对目标状态分布估计。

1.3 模型结果融合输出^[6-8]

传统 IMM 算法是用各个模型滤波结果与模型概率加权乘积求和后得到目标状态分布更新, 所以 IMM 是一种趋势控制正确的近似估计, 而不是统计意义下的最优估计。本文采用贝叶斯后验估计融合方法得到最优后验概率分布估计, 在第 2 步中得到各个模型的卡尔曼滤波状态矢量, 每一个结果代表了模型后验概率目标分布估计, 根据式(9)得到第 j 个模型的目标状态后验概率分布为 $N_j(\hat{\mathbf{x}}_j(k|k), P_j(k|k))$, 那么根据贝叶斯估计原理, 由 r 个滤波模型同时产生的目标状态后验分布可表示为: $P(\mathbf{x}(k|k)|\mathbf{x}_1(k|k), \dots, \mathbf{x}_r(k|k))$, 由于各个模型间是相互独立多维高斯分布, 因此有:

$$P(\mathbf{x}(k|k)|\mathbf{x}_1(k|k), \dots, \mathbf{x}_r(k|k)) \propto$$

$$P(\mathbf{x}(k|k)|\mathbf{x}_1(k|k)) \times \dots \times P(\mathbf{x}(k|k)|\mathbf{x}_r(k|k)) \quad (11)$$

根据贝叶斯估计原理, 最佳估计就是后验概率分布的期望, 即:

$$\hat{\mathbf{x}}(k|k) = \int P(\mathbf{x}(k|k)|\mathbf{x}_1(k|k), \dots, \mathbf{x}_r(k|k)) d\mathbf{x}(k|k) \quad (12)$$

而对于模型 j , 由式(10)得到概率表达式为:

$$P(\mathbf{x}(k|k)|\mathbf{x}_j(k|k)) = N_j(\mathbf{x}(k|k); \hat{\mathbf{x}}_j(k|k), P_j(k|k)) \quad (13)$$

从而结合式(10), 得到融合后状态分布显式表达, 得到融合期望均值和协方差如下:

$$\hat{\mathbf{x}}(k|k) = P(k|k) \cdot \left(\sum_{j=1}^r P_j^{-1}(k|k) \right)^{-1} \cdot \hat{\mathbf{x}}_j(k|k) \quad (14)$$

$$P(k|k) = \left[\sum_{j=1}^r P_j^{-1}(k|k) \right]^{-1} \quad (15)$$

本步骤完成了目标状态融合, 获得了贝叶斯后验概率分布的最优估计。

1.4 模型概率更新

传统的 IMM 算法中, 模型概率更新是通过残差及协方差, 计算残差的似然度, 再结合模型输入交互概率来计算模型概率, 没有考虑多模型交互更新后的目标分布。本文用多模型融合后的目标状态分布计算各个模型似然函数, 可以消除部分状态预测误差和观测值误差影响, 提高模型准确度。在第 3 步, 多模型融合结果输出代表了最优贝叶斯后验估计的目标状态分布, 以各个模型滤波结果在融合输出分布的似然函数, 作为模型概率更新的似然度, 来更新模型概率, 根据似然函数公式, 模型 j 的似然函数计算为:

$$\Lambda_j(k) = P(\hat{\mathbf{x}}_j(k|k)|\hat{\mathbf{x}}(k|k))$$

$$= N[\hat{\mathbf{x}}_j(k|k); \hat{\mathbf{x}}(k|k), P(k|k)] \quad (16)$$

以 u_j 表示模型概率, 根据概率空间完备性总和为 1, 即:

$$\sum_{j=1}^r u_j = 1 \quad (17)$$

概率空间由似然函数构成, 所以概率空间根据模型似然度归一化为:

$$\mu_j(k) = \frac{\Lambda_j(k)}{\sum_{j=1}^r \Lambda_j(k)} \quad (18)$$

本步骤完成了模型概率更新计算, 为 1.1 节 $k+1$ 时刻计算模型转移概率提供了输入。

1.5 模型间转移概率计算

传统的 IMM 算法中, 马尔可夫概率转移矩阵是固定取值。本文提出了以各个模型滤波值为中心, 各个模型滤波输出结果代表了该处理方法对目标状态分布的估计, 模型交互定义为各个模型处理的结果在其他模型输出分布的似然函数, 作为模型转化概率更新值。即模型 i 的滤波值在模型 j 的目标状态分布似然函数, 作为模型 i 在模型 j 的概率分布; 模型 j 自身的似然度由自身模型计算, 从而模型 i 到模型 j 的似然函数为:

$$\Lambda_{ij}(k) = P(\hat{\mathbf{x}}_i(k|k)|\hat{\mathbf{x}}_j(k|k))$$

$$= N[\hat{\mathbf{x}}_i(k|k); \hat{\mathbf{x}}_j(k|k), P_j(k|k)] \quad (19)$$

π_{ij} 表示模型 i 到模型 j 的转移概率, j 取值 1 到 r , 根据概率空间完备性概率总和为 1。

$$\sum_{j=1}^r \pi_{ij} = 1, i \in [1, 2, \dots, r] \quad (20)$$

概率空间由模型似然函数构成, 所以模型转化概率由似然度归一化, 从而有:

$$\pi_{ij} = \frac{\Lambda_{ij}(k)}{\sum_{j=1}^r \Lambda_{ij}(k)} \quad (21)$$

本步骤得到模型间转移概率, 为 1.1 节提供了 $k+1$ 时刻时变 Markov 转移概率矩阵。

2 时变 IMM 与常规 IMM 方法仿真比较

2.1 仿真场景设计

时变 IMM 融合方法与常规 IMM 方法进行了蒙特卡罗仿真对比, 模拟两类不易跟踪的目标场景, 强机动目标场景和强扰动静态目标场景, 进行了 50 次随机航路的仿真。首先根据 Kalman 滤波原理, 对目标状态空间和目标观测空间建模。

(1) 目标状态空间建模

机动目标的运动模型可以通过具有加性加速度高斯噪声的统计来描述, 所以本文采用匀速目标状态叠加加速度噪声模型来建模, 通过控制参数和状态初始化, 模拟产生强机动目标和静态扰动目标。

目标状态方程为:

$$\mathbf{X}(k) = \Phi \cdot \mathbf{X}(k-1) + \mathbf{w}(k) \quad (22)$$

其中:目标状态矢量 $X=[x, y, \dot{x}, \dot{y}]^T$,机动目标初始化 $[1 \ 1 \ 0.1 \ 0.1]^T$,静态目标初始化 $[1 \ 1 \ 0 \ 0]^T$,机动目标状

态转移矩阵 $\phi = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$,静态目标状态转移矩阵

$$\phi = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}。$$

$w(k)$ 的机动目标协方差矩阵为:

$$Q = a^2 \begin{bmatrix} \Delta t^4/4 & 0 & \Delta t^3/2 & 0 \\ 0 & \Delta t^4/4 & 0 & \Delta t^3/2 \\ \Delta t^3/2 & 0 & \Delta t^2 & 0 \\ 0 & \Delta t^3/2 & 0 & \Delta t^2 \end{bmatrix}$$

其中 a 为加速度标准差,取值为0.2。

扰动静态目标协方差矩阵为:

$$Q = a^2 \begin{bmatrix} \Delta t^2 & 0 & 0 & 0 \\ 0 & \Delta t^2 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

其中 a 为速度标准差,取值为0.2。 Δt 取值为0.5。

(2)目标观测空间建模

采用两种模型建立观测空间,模型1是位置模型,模型2是常速度模型对目标跟踪。观测目标状态为:

$$Z_i(k) = H_i(k)X(k) + V_i(k), \quad i=1, 2 \quad (23)$$

其中:模型1观测矩阵 $H_1 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$,模型1观测噪声

$V_1(k)$ 的协方差矩阵为 $R_1 = b^2 \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$,其中 b 为模型1观测误差,取值为0.5。

$$\text{模型2观测矩阵 } H_2 = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \text{模型2观测噪声}$$

$V_2(k)$ 的协方差矩阵为 $R_2 = b^2 \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$,其中 b 为模型2

观测误差,取值为0.5。

(3)常规IMM算法马尔可夫转移概率矩阵:

$$\pi = \begin{bmatrix} 0.95 & 0.05 \\ 0.05 & 0.95 \end{bmatrix} \quad (24)$$

2.2 仿真结果

2.2.1 强机动目标仿真结果

根据2.1节的建模进行仿真,由于加速度较大,因此目标始终处于强机动状态,单次航路仿真跟踪曲线见图2,

仿真了目标真实位置、模型1跟踪、模型2跟踪、时变IMM融合跟踪、常规IMM跟踪,共计5条曲线,从图可见,4种方法都可以跟踪目标。图3是航路误差统计。




图2 强机动目标航路跟踪仿真结果图




图3 强机动目标误差跟踪仿真结果图

强机动目标50次随机航路蒙特卡罗仿真结果如图4所示,可见时变IMM融合方法效果最好,航迹误差曲线在最下方,而常规IMM方法误差曲线介于两个模型之间。航迹误差统计分布结果见表1。

2.2.2 强扰动静态目标仿真结果

强扰动静态目标一次航路仿真跟踪曲线见图5,从图5可见,模型2跟踪发散,模型1、时变IMM融合和常规IMM方法可以跟踪目标。图6是航路误差统计,可见时变IMM融合精度最好,常规IMM精度在两个单模型之间。

强扰动静态目标50次蒙特卡罗仿真精度结果如图7所示,时变IMM融合方法航迹误差曲线精度最好,分布




图4 强机动目标50次蒙特卡罗误差仿真结果

表1 强机动目标蒙特卡罗仿真结果分析表

误差	模型1	模型2	时变IMM	常规IMM
均值	0.392	0.279	0.248	0.337
标准差	0.029	0.029	0.022	0.044

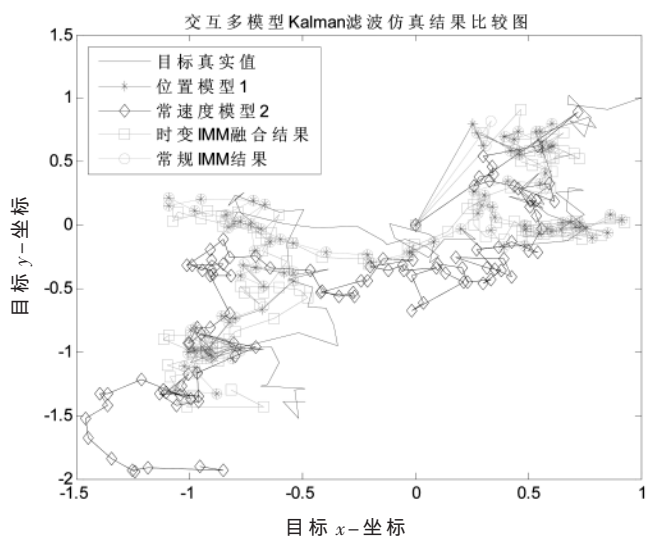


图5 强扰动静态目标航路跟踪仿真图

在下方。统计的航迹误差分布结果见表2,时变IMM融合效果显著。

3 结论

本文应用似然函数理论实现了时变马尔可夫概率转移矩阵和目标模型概率更新方法,应用贝叶斯估计理论实现了多模型融合,得到目标最优贝叶斯后验准确估计。蒙特卡罗仿真结果验证表明,传统IMM方法可以解决目标跟踪的连续性问题,但是并没有提高跟踪精度,相反时变IMM融合方法不但解决了目标跟踪的连续性问题,还提高了跟踪精度。时变IMM融合方法在航迹跟踪连续性、航迹误差和精度方面,统计结果都优于传统




图6 强扰动静态目标误差仿真图




图7 强扰动静态目标50次蒙特卡罗误差仿真结果

表2 强扰动静态目标蒙特卡罗仿真结果分析表

误差	模型1	模型2	时变IMM	常规IMM
均值	0.282	0.738	0.258	0.302
标准差	0.028	0.095	0.025	0.036

IMM方法,原因是时变IMM融合方法与目标实际状态更加吻合。所以理论和仿真结果都表明时变IMM融合算法能更加准确及时地跟踪目标,对跟踪复杂机动目标有现实意义。

参考文献

- [1] 聂晓华.自适应交互多模型火控跟踪算法[J].火力与指挥控制,2007(1):77-80.
- [2] LI X R, JIKOV V P. Survey of maneuvering target tracking-part V: multiple-model methods[J]. IEEE Transactions on Aerospace and Electronic Systems, 2005, 41(4): 1255-1321.
- [3] 秦雷,李君龙,周荻.基于交互式多模型算法跟踪临近空间目标[J].系统工程与电子技术,2014,36(7):1243-1249.

- [4] KOVVALI N, BANAVAR M, SPANIAS A. An introduction to Kalman filtering with MATLAB examples[M]. Morgan & Claypool, 2014.
- [5] KALMAN R. A new approach to linear filtering and prediction problems[J]. Trans. ASME Ser. D. J. Basic Eng., 1960, 82: 35-45.
- [6] 彭丁聪. 卡尔曼滤波的基本原理及应用[J]. 软件导刊, 2009, 8(11): 32-34.
- [7] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 53-70, 121-169.
- [8] 鄂群, 门金柱, 姚科明. 贝叶斯多目标跟踪[M]. 第2版. 北

京: 国防工业出版社, 2016: 37-60.

(收稿日期: 2021-03-24)

作者简介:

栾铸徵(1975-), 通信作者, 男, 硕士, 高级工程师, 主要研究方向: 搜索雷达系统设计, E-mail: yangzhou0514@126.com.

俞成龙(1981-), 男, 硕士, 高级工程师, 主要研究方向: 火控雷达系统设计。

顾兵(1980-), 男, 硕士, 高级工程师, 主要研究方向: 搜索雷达系统设计。



扫码下载电子文档

(上接第 104 页)




图 13 放入干式水表的标签天线测试结果

4 结论

本文针对干式水表复杂的内部结构在 PCB RFID 弯折偶极子天线的基础上设计了一种内凹弯折的电小环结构, 尺寸为 54 mm×11 mm, 读距离为 3.2 m, 在完成天线小型化设计的同时满足了金属类干式水表产品追溯的现实要求。另一方面, 本文所设计的内凹弯折电小环结构为弯折偶极子天线适用不同结构的设计提供了新的思路, 未来可将其推广至更多的应用领域。

参考文献

- [1] 杨滨, 王振杰, 朱珍香, 等. 干式单流束水表流量性能误差原因分析[J]. 仪表技术, 2020(9): 24-26.
- [2] 陈硕, 刘丰, 唐旭晟, 等. 基于机器视觉技术的水表在线检定系统研究[J]. 计量学报, 2017, 38(4): 473-476.
- [3] 韩涛, Zhang Mingjun, 王红成, 等. 一种小型 UHF RFID 抗金属标签天线的设计[J]. 电讯技术, 2016, 56(1): 71-75.
- [4] 景裕文, 崔英花. 一种小型无源 UHF 抗金属标签天线的设计[J]. 电子技术应用, 2018, 44(11): 13-16.
- [5] 赵犁, 郜笙, 虞俊俊. 金属介质对超高频 RFID 被动标签

读取效能的影响及可用于金属表面标签的设计[J]. 工程设计学报, 2006(6): 416-420, 430.

- [6] Wang Xiumei, Jiang Kaiming. Design of an UHF RFID Anti-metal Tag Antenna[J]. International Core Journal of Engineering, 2020, 6(5).
- [7] 牛中奇, 朱满座, 卢智远, 等. 电磁场理论基础[M]. 北京: 电子工业出版社, 2001.
- [8] 郭宗鑫, 张丕状, 姚金杰, 等. 基于 RFID 新型抗金属标签设计[J]. 国外电子测量技术, 2019, 38(12): 115-119.
- [9] 代孝俊, 杜国宏, 邓伟, 等. 用于手术刀的抗金属无源 RFID 标签天线设计[J]. 微波学报, 2019, 35(2): 60-63.
- [10] 张同飞. 超高频 RFID 抗金属电子标签天线研究[C]//天津市电子学会、天津市仪器仪表学会. 第三十二届中国(天津)2018 IT、网络、信息技术、电子、仪器仪表创新学术会议论文集, 2018.
- [11] Huang Yi, BOYLE K. Antennas: from Theory to practice[M]. Wiley 2008.
- [12] 贺则昊, 洪涛, 陈家焱, 等. 智能仪表 PCB 集成化 RFID 标签天线设计优化[J]. 电子技术应用, 2020, 46(2): 62-66, 70.
- [13] 章伟. UHF RFID 标签天线设计、仿真及实践[M]. 北京: 电子工业出版社, 2012.
- [14] 李宏阳. RFID 标签天线设计及工程应用研究[D]. 成都: 西南交通大学, 2018.
- [15] 赖晓铮, 张小燕, 赖声礼. 弯折线偶极子天线谐振特性的研究[J]. 微波学报, 2006(3): 18-22.
- [16] 唐智斌. 超高频 RFID 标签天线的设计与实现[D]. 北京: 中国科学院大学, 2016.

(收稿日期: 2020-12-12)

作者简介:

王翠(1995-), 女, 硕士研究生, 主要研究方向为 RFID 天线设计。

洪涛(1970-), 通信作者, 男, 硕士, 高级工程师, 主要研究方向: RFID 质量追溯系统研究, E-mail: hongtao@cjlu.edu.cn.



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所