

基于可能模型集的期望模式增广算法

周晓辉, 张剑云, 程水英

(电子工程学院, 安徽 合肥 230037)

摘要: 提出一类基于可能模型集(lively-model set, LMS)的期望模式增广(expected-mode augmentation, EMA)算法, 该算法将任意时刻的有效模型集分成可能模型集和增广模型集两个部分。可能模型集由模型后验概率和总模型集的拓扑图确定; 对可能模型集加权组合, 生成增广模型集。然后, 基于两模型集的并集对目标的状态进行估计。该算法能够保持期望模式增广算法的精度, 同时大大降低计算量。仿真结果验证了本文算法的性能。

关键词: 机动目标; 跟踪; 期望模式; 可能模型集; 变结构

中图分类号: TN 953

文献标志码: A

DOI: 10.3969/j. issn. 1001-506X. 2010. 11. 09

Expected-mode augmentation algorithm based on likely-model set

ZHOU Xiao-hui, ZHANG Jian-yun, CHENG Shui-ying

(Electronic Engineering Inst., Hefei 230037, China)

Abstract: A class of expected-mode augmentation (EMA) algorithm based on likely-model set (LMS) is proposed. The effective model set is divided into LMS and expected-mode set at each time step. The LMS is decided according to the posterior model probabilities and the topology, and the expected-mode set is generated by the weighted combination of the likely-model set. Then, the target state is estimated based on the union set of the two model sets. The algorithm maintains the precision of the EMA algorithm and reduces the computational load. Simulation results validate the performance of the algorithm.

Keywords: maneuvering target; tracking; expected-mode; likely-model set (LMS); variable structure

0 引言

机动目标跟踪是一个混合估计问题, 在量测已知的条件下, 其困难主要来自于目标机动模式不确定。多模型方法以其优越的性能, 在机动目标跟踪领域得到了广泛的应用和发展^[1-5], 被公认为解决目标机动不确定性问题的主流方法。早期的多模型方法一般采用固定的模型集, 在应用中, 常面临一个困境: 对于实际的跟踪场景, 往往需要设计和使用很大的模型集来包含目标所有可能的运动模式, 导致计算量很大, 实时性较差; 另外, 为了提高算法的性能, 需要增加模型的数目, 但太多的模型未必能提高算法的性能, 却必定会增加计算量^[6]。变结构多模型(variable structure multiple-model, VSMM)方法就是为摆脱这种困境而发展起来的, 它能够根据目标的实际运动模式自动调整模型集, 实现采用较小的模型集来匹配目标的运动模式的目的。

期望模式增广(expected-mode augmentation, EMA)算法^[5]是 VSMM 算法的一种, 它通过对当前模型集中的多个模型加权组合, 自适应地生成几个期望模式来近似目标的

实际运动模式, 使该算法具有较高的估计精度。然而, 其任意时刻的模型数目都是固定的, 其中不匹配的模型, 可能会降低估计精度, 且增加不必要的计算量。可能模型集(lively-model set, LMS)算法^[4]通过激活、保留、舍弃等措施来自适应选择模型集, 具有模型集管理功能。本文算法的思路就是把 LMS 的思想引入到 EMA 算法中, 对 EMA 中的固定模型集进行有效的管理, 删减其中明显不匹配的模型, 从而减小 EMA 算法的计算。

1 问题描述

机动目标跟踪就是对以下两方程描述的随机系统^[7]的状态进行估计的过程

$$\mathbf{x}_{k+1} = \mathbf{f}_k(\mathbf{x}_k, \mathbf{s}_{k+1}) + \mathbf{g}_k[\mathbf{x}_k, \mathbf{s}_{k+1}, \mathbf{w}_k(\mathbf{x}_k, \mathbf{s}_{k+1})] \quad (1)$$

$$\mathbf{z}_k = \mathbf{h}_k(\mathbf{x}_k, \mathbf{s}_k) + \mathbf{v}_k(\mathbf{x}_k, \mathbf{s}_k) \quad (2)$$

式中, k 是离散时间变量; \mathbf{x}_k 为基础状态变量; \mathbf{s}_k 为系统模式空间 S 上的模式变量; \mathbf{z}_k 是 k 时刻的量测; \mathbf{w}_k 和 \mathbf{v}_k 分别为系统的过过程噪声和量测噪声。系统模式序列假定是一个齐次马尔可夫链, 具有转移概率

$$p(s_{k+1} = m_j \mid s_k = m_i) = \pi_{ij}, \forall m_i, m_j \in \mathbf{S} \quad (3)$$

多模型方法被认为是解决目标机动不确定性问题的有效方法,它将由以下两个方程描述的几个模型进行适当组合来近似目标的实际运动模式

$$\mathbf{x}_{k+1} = \mathbf{F}_k \mathbf{x}_k + \mathbf{G}_k \mathbf{u}_k^i + \boldsymbol{\Gamma}_k^i \mathbf{w}_k^i, \forall m_i \in \mathbf{M} \quad (4)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k, \forall m_i \in \mathbf{M} \quad (5)$$

式中, \mathbf{G}_k^i 和 \mathbf{u}_k^i 分别表示与模式 m_i 对应的系统控制矩阵和系统输入; \mathbf{M} 表示总模型集。

由于目标的实际运动模式包含在一个很大的连续空间中,采用固定模型集结构通常不能充分描述目标的运动真实模式,这种缺陷导致 VSMM 算法的产生和发展。VSMM 算法根据实际情况自适应选择或生成模型,具有一定的模型集自适应功能。基于最小均方误差(minimum mean square error, MMSE)准则,VSMM 算法的估计及其协方差矩阵^[6]为

$$\hat{\mathbf{x}}_{k|k} = \sum_j \hat{\mathbf{x}}_{k|k}^{(j)} p(h_{(j)}^k \mid Z^k) \quad (6)$$

$$\mathbf{P}_{k|k} = \sum_j \{ \mathbf{P}_{k|k}^{(j)} + [\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(j)}] [\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(j)}]^T \} p(h_{(j)}^k \mid Z^k) \quad (7)$$

式中, Z^k 表示直到 k 时刻的量测序列; $h_{(j)}^k$ 表示事件“直到 k 时刻的量测序列 j 匹配目标的实际运动模式序列”; $\hat{\mathbf{x}}_{k|k}^{(j)}$ 表示基于该事件的最优估计; $\mathbf{P}_{k|k}^{(j)}$ 表示相应的误差协方差矩阵。由于模型集序列随时间呈指数增长,所以式(6)、式(7)关于 VSMM 算法的估计实际是不可行的;然而,有一种简单、近似的方法计算其状态估计及误差协方差矩阵

$$\hat{\mathbf{x}}_{k|k} = \sum_{m_j \in M_k} \hat{\mathbf{x}}_{k|k}^{(j)} p(s_k = m_j \mid Z^k) \quad (8)$$

$$\mathbf{P}_{k|k} = \sum_{m_j \in M_k} \{ \mathbf{P}_{k|k}^{(j)} + [\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(j)}] [\hat{\mathbf{x}}_{k|k} - \hat{\mathbf{x}}_{k|k}^{(j)}]^T \} p(s_k = m_j \mid Z^k) \quad (9)$$

2 基于 LMS 的 EMA 算法(LMS-EMA)

LMS-EMA 是一种递推算法,每一个周期($k-1$ 到 k 时刻)包括三个部分内容:可能模型集确定;期望模式集生成;基于可能模型集和期望模式集的并集的多模估计。

设 M_k 和 E_k 分别表示 k 时刻的有效模型集和增广模型集,令 $M_k^f = M_k - E_k$ 。为了有效利用增广模型集,使 E_k 始终保存在有效模型集中,即, $E_k \subset M_k$ 在任意时刻 k 均成立。在 M_{k-1} 的基础上,如何确定 M_k 是 LMS-EMA 首先要解决的问题。将 M_{k-1}^f 中的模型按其后验概率分为主模型集 ($\mu_{k-1}^{(i)} > T_h$)、重要模型集 ($T_l \leq \mu_{k-1}^{(i)} \leq T_h$) 和不可能模型集 ($\mu_{k-1}^{(i)} < T_l$);保留重要模型集,激活与主要模型集相通的模型集,同时删除不可能模型集,可以确定模型集 M_k^f 。由于 E_{k-1} 的特殊性,其不参与可能模型集算法的运算。

k 时刻的增广模型 E_k 可由不同的方法计算得到,采用基于 M_{k-1} 的预测模型概率加权可得

$$E_k = E(M_{k-1}) = \sum_{m_i \in M_{k-1}} m_i \hat{\mu}_{k|k-1}^{(i)} \quad (10)$$

式中, $\hat{\mu}_{k|k-1}^{(i)}$ 表示模型 m_i 的预测概率。采用基于 M_k^f 的后验概率加权可得

$$E_k = E(M_k^f) = \sum_{m_j \in M_k^f} m_j \mu_k^{(j)} \quad (11)$$

式中, $\mu_k^{(j)}$ 表示模型 m_j 的后验概率。

由 M_k^f 和 E_k 得到 k 时刻的有效模型集 $M_k = M_k^f \cup E_k$ 。接下来就是如何进行有效估计的问题,这可以由变结构交互式多模型(variable structure interacting multiple-model, VSIMM) $[M_k, M_{k-1}]$ ^[8] 递归计算得到。另外,还要解决基于两集合的并集的估计融合问题。

设 M_k^1 和 M_k^2 是 k 时刻的两个模型集($M_k^1 \cup M_k^2 = M_k$),他们具有相同的模型集历史 M^{k-1} ,通过 VSIMM 算法可得 $\{\hat{\mathbf{x}}_{k|k}^{(i)}, \mathbf{P}_{k|k}^{(i)}, L_k^{(i)}, \hat{\mu}_{k|k-1}^{(i)}\}_{m_i \in M_k^1}$, $\{\hat{\mathbf{x}}_{k|k}^{(i)}, \mathbf{P}_{k|k}^{(i)}, L_k^{(i)}, \hat{\mu}_{k|k-1}^{(i)}\}_{m_i \in M_k^2}$ 则基于模型集序列 $\{M_k, M^{k-1}\}$ 的最优估计和相应的误差协方差矩阵可以由 VSIMM $[M_k^1, M_{k-1}]$ 和 VSIMM $[M_k^2, M_{k-1}]$ 融合得到^[9]

$$\hat{\mathbf{x}}_{k|k} = \sum_{m_i \in M_k} \hat{\mathbf{x}}_{k|k}^{(i)} \mu_k^{(i)} \quad (12)$$

$$\mathbf{P}_{k|k} = \sum_{m_j \in M_k} [\mathbf{P}_{k|k}^{(j)} + (\hat{\mathbf{x}}_{k|k}^{(j)} - \hat{\mathbf{x}}_{k|k}) (\hat{\mathbf{x}}_{k|k}^{(j)} - \hat{\mathbf{x}}_{k|k})^T] \mu_k^{(j)} \quad (13)$$

$$\mu_k^{(j)} = p\{m_k^{(j)} \mid M_k, M^{k-1}, z^k\} = \frac{L_k^{(j)} \hat{\mu}_{k|k-1}^{(j)}}{\sum_{m_j \in M_k} L_k^{(j)} \hat{\mu}_{k|k-1}^{(j)}} \quad (14)$$

该融合算法记为 EF $\{\text{VSIMM}[M_k^1, M_{k-1}], \text{VSIMM}[M_k^2, M_{k-1}]\}$ 。

根据增广模型集 E_k 的计算方法不同,提出了两种 EMA-LMS 算法;算法的一个周期如下。

2.1 LMS-EMA-A(L-E-A)算法的一个周期

步骤 1 根据模型集 M_{k-1} 中各模型的预测概率 $\{\mu_{k|k-1}^{(i)}\}_{m_i \in M_{k-1}}$,求出期望模式集 $E_k = E(M_{k-1})$;则 k 时刻的有效模型集 $M_k = M_k^f \cup E_k$ 。

步骤 2 运行 VSIMM $[M_k, M_{k-1}]$ 一个周期,求出各模型的概率 $\{\mu_k^{(i)}\}_{m_i \in M_k}$ 。

步骤 3 对模型集 M_k^f 中模型的概率进行重归一化。

$$\mu_k'^{(i)} = \mu_k^{(i)} / \sum_{m_i \in M_k^f} \mu_k^{(i)}$$

将模型集 M_k^f 中的所有模型 m_i 归类为主要模型集($\mu_k'^{(i)} > T_h$),重要模型集($T_l \leq \mu_k'^{(i)} \leq T_h$)和不可能模型集($\mu_k'^{(i)} < T_l$)。令不可能模型集为 M_u 。

步骤 4 若没有主要模型,令 $M_a = \emptyset$ 并转到步骤 5;否则,找出与任一主要模型相通的所有模型组成的集合 M_a 。求得新模型集 $M_n = M_a \cap \bar{M}_k$ (\bar{M}_k 是 M_k 的补集)和并集 $M_k := M_k \cup M_n$, $M_k^f := M_k^f \cup M_n$,然后

(1) 运行 VSIMM $[M_n, M_{k-1}]$ 周期。

(2) 融合 EF $\{\text{VSIMM}[M_k, M_{k-1}]\}$ 和 VSIMM $[M_n, M_{k-1}]$ 。

$M_{k-1}]$ }, 得到基于并集 M_k 的总体估计、误差协方差矩阵和模型概率 $\{\hat{x}_{k|k}, P_{k|k}, \mu_k^{(i)}\}$, $\forall m_i \in M_k$ 。

步骤 5 输出 $\hat{x}_{k|k}, P_{k|k}$ 和所有的 $\{\mu_k^{(i)}\}_{m_i \in M_k}$ 。

步骤 6 若没有不可能模型, 令 $M_{k+1}^f = M_k^f$, 并返回步骤 1; 否则, 确定要抛弃的模型集 $M_d = M_u \cap \bar{M}_a$, 它是不可能模型集中不与任何主要模型相通的模型的集合。

步骤 7 从集合 M_k^f 中去掉具有较小概率并且包含于 M_d 中的模型, 并使 M_k^f 中至少包含 K 个模型, 也就是说, $k+1$ 时刻的可能模型集为 $M_l = M_k^f - M_m$, 其中, M_m 是 M_d 中具有较小概率并保证 $M_k^f - M_m$ 至少包含 K 个模型的模型集。

步骤 8 令 $M_{k+1}^f = M_l$, 返回步骤 1。

2.2 LMS-EMA-B(L-E-B)算法的一个周期

步骤 1 运行 VSIMM $[M_k^f, M_{k-1}]$ 一个周期, 求出 $\{\mu_k^{(i)}\}$, $\hat{x}_{k|k}^{(i)}, P_{k|k}^{(i)}\}_{m_i \in M_k^f}$ 。

步骤 2 利用当前更新的模型概率 $\{\mu_k^{(i)}\}_{m_i \in M_k^f}$, 计算 $E_k = E(M_k^f) = \sum_{m_i \in M_k^f} m_i u_k^{(i)}$, 则 k 时刻的有效模型集 $M_k = M_k^f \cup E_k$ 。

步骤 3 将模型集 M_k^f 中的所有模型 m_i 归类为主要模型集 ($\mu_k^{(i)} > T_h$), 重要模型集 ($T_l \leq \mu_k^{(i)} \leq T_h$) 和不可能模型集 ($\mu_k^{(i)} < T_l$); 令不可能模型集为 M_a 。

步骤 4 若没有主要模型, 令 $M_a = \emptyset$ 并转到步骤 5; 否则, 找出与任一主要模型相通的所有模型组成的集合 M_a 。求得新模型集 $M_n = M_a \cap \bar{M}_k$ (其中, \bar{M}_k 是 M_k 的补集) 和并集 $M_k := M_k \cup M_n, M_k^f := M_k^f \cup M_n$, 然后

(1) 运行 VSIMM $[M_n \cup E_k, M_{k-1}]$ 周期, 其中 M_n 是由新的并且仅仅是由新的模型组成的集合。

(2) EF {VSIMM $[M_k^f, M_{k-1}]$, VSIMM $[M_n \cup E_k, M_{k-1}]$ }, 得到基于并集 M_k 的总体估计、误差协方差矩阵和模型概率 $\{\hat{x}_{k|k}, P_{k|k}, \mu_k^{(i)}\}$, $\forall m_i \in M_k$ 。跳转到步骤 6。

步骤 5 运行 VSIMM $[E_k, M_{k-1}]$ 一个周期;

融合 EF {VSIMM $[M_k^f, M_{k-1}]$ 和 VSIMM $[E_k, M_{k-1}]$ }, 得到基于有效模型集 M_k 的总体估计、误差协方差矩阵和模型概率 $\{\hat{x}_{k|k}, P_{k|k}, \mu_k^{(i)}\}$, $\forall m_i \in M_k$ 。

步骤 6 输出 $\hat{x}_{k|k}, P_{k|k}$ 和所有的 $\{\mu_k^{(i)}\}_{m_i \in M_k}$ 。

步骤 7 若没有不可能模型, 令 $M_{k+1}^f = M_k^f$, 返回步骤 1; 否则, 确定要抛弃的模型集 $M_d = M_u \cap \bar{M}_a$, 它是不可能模型集中不与任何主要模型相通的模型的集合。

步骤 8 从集合 M_k^f 中去掉具有较小概率并且包含于 M_d 中的模型, 并使 M_k^f 中至少包含 K 个模型, 也就是说, $k+1$ 时刻的可能模型集合为 $M_l = M_k^f - M_m$, 其中, M_m 是 M_d 中具有较小概率并保证 $M_k^f - M_m$ 至少包含 K 个模型的模型集。

步骤 9 令 $M_{k+1}^f = M_l$, 返回步骤 1。

3 仿真分析

为了验证本文算法的性能, 采用 13 个固定模型集结合

1 个增广模型集, 跟踪文献[5]中的确定性场景 1(DS1)和确定性场景 2(DS2)。DS1 中目标在任意时刻的实际运动模式(加速度矢量)比较靠近拓扑图 1 中的某个网格点(模型); DS2 中目标的实际运动模式一般不靠近图 1 中的网格点。固定模型结合增广模型的拓扑图如图 2 所示, 其中, m_e 表示增广模型, 并且与其他模型是相通的, 由于结构太复杂, 这里未画出来。概率转移矩阵以及其他条件与文献[5]给出的条件相同, 这里不再赘述。

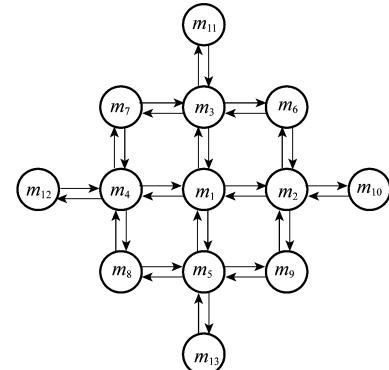


图 1 固定模型集的拓扑图

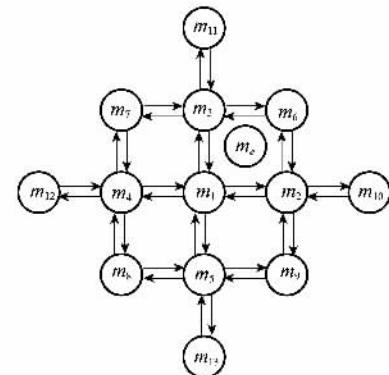


图 2 固定模型结合增广模型的拓扑图

本文算法均进行 500 次蒙特卡罗仿真。首先, 将本文提出的两种算法 L-E-A 和 L-E-B 与交互式多模型(interacting multiple-model, IMM)和 LMS 算法进行比较。采用这四种算法跟踪 DS1 和 DS2 中机动目标, 得到位置和速度的均方根误差(root mean square error, RMSE)分别如图 3 和图 4 所示。可以看出在 DS1 中, L-E-A 和 L-E-B 略微优于 IMM 和 LMS 算法; 在 DS2 中, L-E-A 和 L-E-B 的估计精度明显高于 IMM 和 LMS 算法。原因是 DS2 中目标的实际运动模式离网格点较远, IMM 和 LMS 采用固定网格点, 其模式失配较大; 而 L-E-A 和 L-E-B 算法能够实时产生期望模型来尽量匹配目标的实际运动模式, 其模式失配较小, 估计精度较高。

其次, 将 L-E-A 和 L-E-B 与文献[5]中的两种算法 EMA-A 和 EMA-B 进行了比较, 如图 5 和图 6 所示。在两

个完全不同的场景中,四种算法具有基本相同的跟踪精度。原因是本文算法只是舍弃了 EMA 算法中固定模型集中不太可能存在(后验概率较小)的模型,这些模型对提高跟踪精度没有明显影响。

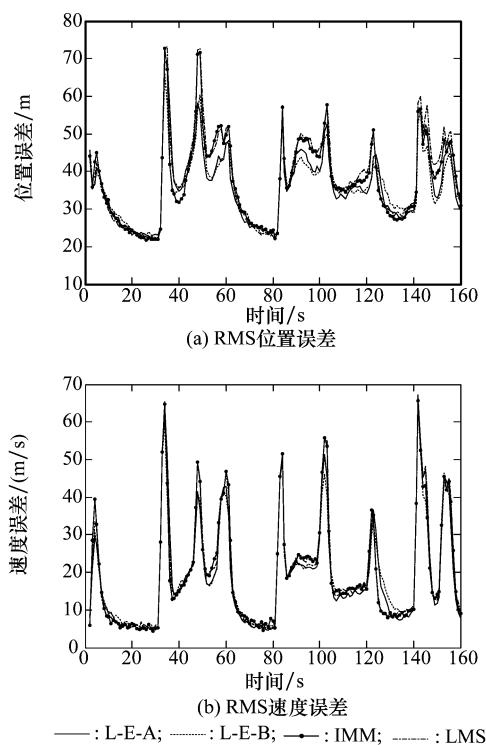


图 3 本文算法与 IMM 和 LMS 算法的比较(DS1)

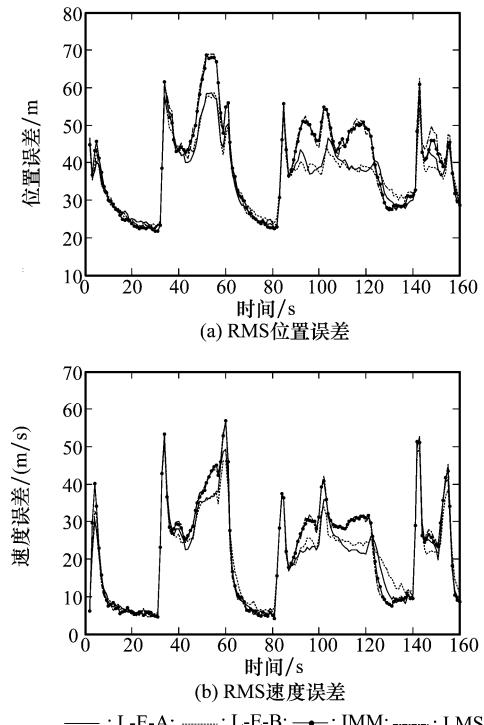


图 4 本文算法与 IMM 和 LMS 算法的比较(DS2)

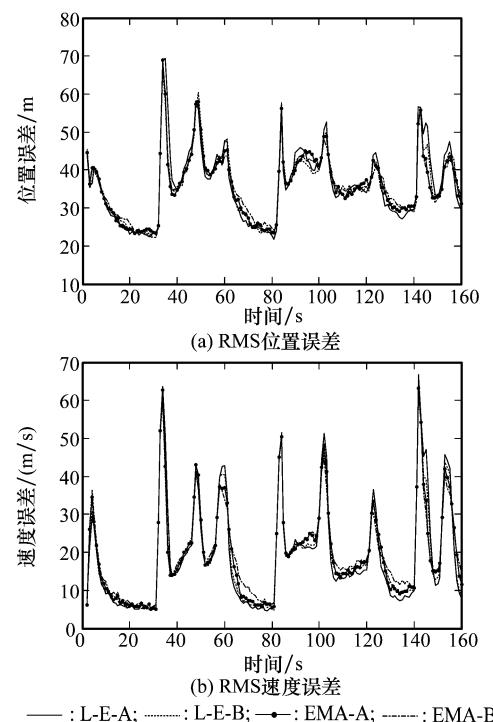


图 5 本文算法与 EMA 算法的比较(DS1)

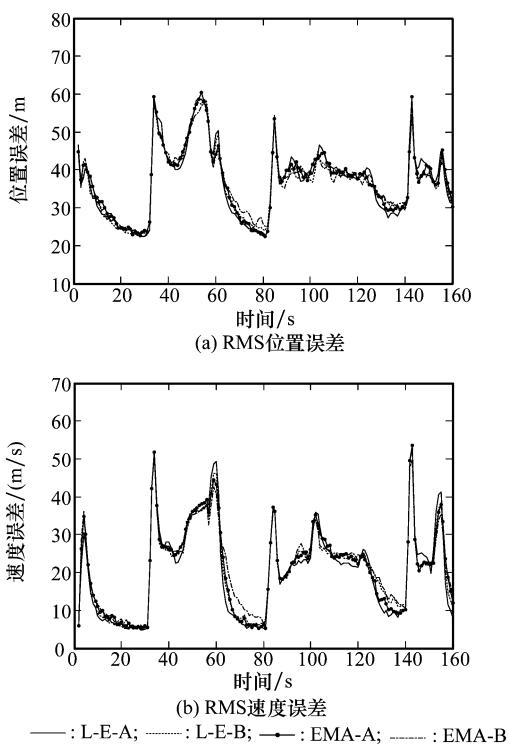


图 6 本文算法与 EMA 算法的比较(DS2)

表 1 和表 2 对几种算法进行了比较,性能指标包括:算法的相对运行时间之比(relative execution time, RET)、RMS 位置误差均值(average root mean square position error, ARMSPE)、RMS 速度误差均值(average root mean square

velocity error, ARMSVE)、RMS 模式误差均值(average root mean square mode error, ARMSME)、位置误差峰值(maximum position error, MAXPE)、速度误差峰值(maximum velocity error, MAXVE)等。从表中可以看出,本文提出的两种算法跟踪精度高于 IMM 和 LMS, 基本与 EMA-A、EMA-B 相同; 计算量明显低于 EMA-A、EMA-B、IMM, 只是略微高于 LMS。

表 1 跟踪 DS1 中机动目标的算法性能比较

算法	RET	ARMSPE	ARMSVE	ARMSME	MAXPE	MAXVE
IMM	1	37.78	19.80	8.43	72.66	65.66
LMS	0.591	38.12	19.88	8.45	73.14	67.13
EMA-A	1.115	35.77	19.49	8.61	68.82	63.24
EMA-B	1.147	36.16	20.07	9.13	66.94	62.44
E-L-A	0.723	36.11	19.12	8.27	69.48	66.67
E-L-B	0.761	36.01	19.25	8.56	66.20	64.16

表 2 跟踪 DS2 中机动目标的算法性能比较

算法	RET	ARMSPE	ARMSVE	ARMSME	MAXPE	MAXVE
IMM	1	39.52	22.21	8.00	68.71	56.83
LMS	0.602	39.64	22.04	7.96	69.04	56.37
EMA-A	1.118	36.98	21.03	8.19	60.32	53.50
EMA-B	1.154	37.08	21.66	9.43	58.23	50.91
E-L-A	0.752	37.02	20.52	7.79	59.33	52.64
E-L-B	0.784	36.90	20.86	8.78	58.63	51.14

4 结束语

本文在分析 LMS 和 EMA 算法优、缺点的基础上, 提出了一类基于可能模型集的期望模式增广算法, 该算法同时具有 LMS 算法的计算量和 EMA 算法的精度, 是一种高效的变结构多模型算法。

参考文献:

- [1] 杨争斌, 郭福成, 周一宇. 迭代 IMM 机动目标被动态单站跟踪算法[J]. 宇航学报, 2008, 29(1): 304–310.
- [2] Farrell J W, III. Interacting multiple model filter for tactical ballistic missile tracking[J]. *IEEE Trans. on Aerospace and Electronic Systems*, 2008, 44(2): 418–426.
- [3] Li X R, Zhi X R, Zhang Y M. Multiple-model estimation with variable structure—part III: model-group switching algorithm[J]. *IEEE Trans. on Aerospace and Electronic Systems*, 1999, 35(1): 225–241.
- [4] Li X R, Zhang Y M. Multiple-model estimation with variable structure—part V: likely-model set algorithm [J]. *IEEE Trans. on Aerospace and Electronic Systems*, 2000, 36(2): 448–466.
- [5] Li X R, Jilkov V P, Ru J F. Multiple-model estimation with variable structure—part VI: expected-mode augmentation [J]. *IEEE Trans. on Aerospace and Electronic Systems*, 2005, 41(3): 853–867.
- [6] Li X R, Bar-Shalom Y. Multiple-model estimation with variable structure [J]. *IEEE Trans. on Automatic Control*, 1996, 41(4): 478–493.
- [7] 韩崇昭, 朱洪艳, 段战胜, 等. 多源信息融合[M]. 北京: 清华大学出版社, 2006: 55.
- [8] Li X R. *Engineer's guide to variable-structure multiple-model estimation for tracking*[M]// Bar-Shalom Y, Blair W D. Multiple-multisensor tracking: applications and advance. Boston, MA: Artech House, 2000: 529.
- [9] Li X R. Model-set sequence conditioned estimation in multiple-model estimation with variable structure [C]// Proc. of SPIE Conference Signal and Data Processing of Small Targets, Orlando, FL, 1998, 3373: 546–558.