

基于 TBM 双层融合架构的航路属性异常检测

王晓华^{1,2}, 邹 杰², 李 立^{1,2}, 梁 彦^{1,2}

(1. 西北工业大学自动化学院, 陕西西安 710072; 2. 光电控制技术重点实验室, 河南洛阳 471009)

摘 要: 航路飞行目标的属性异常检测是确保及时发现飞行异常的关键问题. 常用的概率框架需要受到先验信息的局限. 可传递置信模型 (Transferable Belief Model, TBM) 不需要先验信息, 能高效处理异质信息, 但是传统的 TBM 无法处理时间上的不连续与不确定性, 因此针对异常航路目标检测问题, 将马尔可夫模型与 TBM 框架结合, 建立了基于 TBM 的双层融合架构, 实现了多特征融合航路属性异常检测. 第一层是通过对多属性冲突信息的分析, 实现对多特征的检测, 并通过特征贡献度分析, 对多特征信息进行打折后再融合; 第二层是通过在时间序列上的指派融合, 对比预测值和观测值差异, 检测航路目标异常变化. 仿真试验验证, 在切换航路场景与偏离回归场景中, 相较动态证据推理方法, 本文方法具有更好的决策准确性与时间精确度.

关键词: 信息融合; 航迹关联; 异常信源; 决策理论

中图分类号: TN958 **文献标识码:** A **文章编号:** 0372-2112 (2017)03-0577-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.03.011

The Anomaly Detection Based on TBM Two-Level Fusion Architecture

WANG Xiao-hua^{1,2}, ZOU Jie², LI Li^{1,2}, LIANG Yan^{1,2}

(1. School of Automation, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China;

2. Key Laboratory of Electrooptical Control Technology, Luoyang, Henan 471009, China)

Abstract: The track anomaly detection is the key issue to make sure flying anomaly detected in time for the route flight. Traditional probabilistic frameworks are always based on prior probabilities. Transferable belief model (TBM) theory can generalize the Bayesian approach without prior probabilities and efficiently deal with heterogeneous data. However, the traditional TBM cannot deal with the discontinuity and uncertainty about the time. Considering the existence of unreliable evidence sources, an alternative anomaly detection method is proposed in the framework of transferable belief model (TBM) theory. A two-level architecture fusion system based on TBM is developed. The novelty of this work is that it can detect both unreliable evidence source and abnormal behavior of the targets within our architecture by using a temporal analysis and a new discounting coefficient through introducing the concept of contribution degrees of features. Detection of abnormal behavior is based on a prediction/observation process and the influence of the faulty sources is weakened through discounting coefficients. The simulations show the better accuracy of decision and precision of time compared with the dynamic evidence reasoning method.

Key words: information fusion; track association; anomaly source data; decision theory

1 引言

航路属性异常检测是保证飞行器安全飞行的重要环节, 航路属性判断是航路属性异常检测中的重要一环, 其常用的判断方法主要有以下四类: (1) 概率模

型^[1,2], 该方法面临的主要问题是多信源冲突; (2) 置信模型^[4], 该类方法解决了信源冲突问题, 但是相比概率模型其损失了更多信息; (3) 联合模型, 联合模糊逻辑与概率方法^[5]; (4) 可传递置信模型 (Transferable Belief Model TBM)^[6,7].

收稿日期: 2015-07-09; 修回日期: 2015-11-20; 责任编辑: 覃怀银

基金项目: 国家自然科学基金 (No. 61135001, No. 61374023, No. 61374159); 航空科学基金 (No. 20125153); 光电控制技术重点实验室和航空科学基金联合资助 (No. 20125153027)

异常检测方法主要有神经网络,模糊逻辑,概率方法以及证据推理方法^[8-10].神经网络可以通过学习来识别行为,但是需要大量的训练时间以及训练样本来达到鲁棒的识别效果^[9].概率方法或者说贝叶斯方法具有高效的异常识别能力^[10],但是传统的概率方法通常需要先验概率,航路航迹情况复杂信息容易缺失,先验概率难以获取.证据推理方法可以在先验信息不完备的情况下检测异常,动态证据推理方法(Dynamic Evidence Reasoning, DER)^[11,12]将证据的可靠性与时间变化相关联,得到更加完备的检测结果,但是其置信衰减因子将证据可靠性仅与时间相关联也会导致错误的推理结果.

可传递置信模型(Transferable Belief Mode, TBM)是证据推理框架下的一种双层推理模型,不需要先验信息,能够高效处理冗余信息与异质信息,可以对未知和完全未知进行很好的定义^[13].在航迹分类问题中,由于杂波密度较大,航路密集等情况,同样面临着信源不可靠,冲突较大的情况.TBM已经证实可以应用在航路关联,但是航路异常检测中鲜见.因为航路异常检测不仅需要处理空间上,还有时间上多航迹和多航路关联的不确定性,传统的TBM算法无法处理,需要发展全新的TBM框架实现基于时空不确定动态信息的航路属性异常检测.本文提出了基于TBM的双层融合架构多特征融合航路属性异常检测方法(TBM Two-level Fusion Architecture, TBMTFA).将航路属性判断与异常检测都置于TBM框架下.在航路异常检测中仅依靠单一时刻航迹点进行决策本身就带有很大的风险,因此,将马尔可夫模型与TBM结合,建立了异常航路目标检测系统,在实现对航路目标属性判断的同时,进行目标异常变化检测.

2 基于TBM的双层融合异常检测系统框架

如图1所示,双层融合异常检测系统的“双层”是指多特征融合航路关联与航路异常变化检测两部分.多特征融合决策可以判断当前的航迹属性,同时其输出的融合值作为异常变化检测的输入值,与预测值融合检测航迹是否出现异常.最终“双层”的输出结果将共同决策航迹属性与异常情况.多特征融合航路关联部分包括了折扣因子计算,多特征融合以及航迹航路关联决策.航路异常变化检测部分将多特征融合结果以及航迹航路预测结果融合后,根据观测mass函数值与预测mass函数值之间的冲突值,来检测航路是否出现异常.航迹航路预测时采用马尔可夫框架更新状态置信值.航路属性异常检测采用“专家”规则对融合结果的冲突值判断是否为异常.最后将航迹编号,异常属性信息进行最后的综合推理与决策.

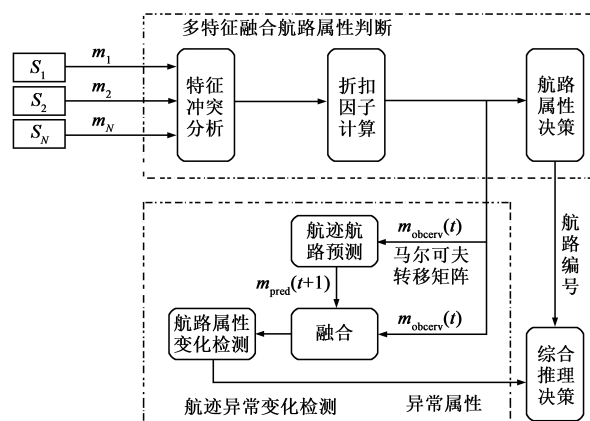


图1 TBMTFA框架

3 多特征航路属性判断

3.1 特征冲突分析

设传感器 S_1 和 S_2 的辨识框架为 $\Theta = \{H_1, H_2\}$. m_1 和 m_2 是根据 S_1 和 S_2 得到的mass函数,两个特征的融合结果 $m_{12}(A) = (m_1 \otimes m_2)(A)$, $m_{12}(\emptyset)$ 则指这两个特征之间的冲突值,但是即使当两个特征得到的mass函数完全相同时, $m_{12}(\emptyset)$ 的值也不会为0,即这个度量不能够准确地反映证据的冲突程度.此外,如果只有两个特征且其冲突值很大的话,将无从判决哪一个特征判断出现异常,所以需要至少三个的特征.采用pairwise规则^[21],对每两个特征进行融合,然后对融合结果进行冲突分析.根据融合结果,如果 $m_{ij}(\emptyset)$ 和 $m_{ik}(\emptyset)$ 都超过某一给定阈值,那么特征 S_i 的判断就有很大的可能性是出现异常了.具体实现如下:

第一步:对 $N(N > 2)$ 个特征进行两两融合,得到两两之间的冲突值:

$$m_{ij}(\emptyset) = \sum_{\substack{A \cap B = \emptyset \\ i, j = 1, \dots, N, i \neq j}} m_i(A) m_j(B) \quad (1)$$

第二步:设计专家系统对第一步得到的 C_N^2 个冲突值进行分析决策,重点关注长期且明显的冲突值.这两个专家评估系统的辨识框架都包含两个假设 H_1 与 H_2 , H_1 为“YES”指特征值正常; H_2 为“NO”指特征值异常,即 $\Theta = \{\text{YES}, \text{NO}\}$.第一个基本信任函数针对 $m_{ij}(\emptyset)$ 的持续时间得到mass函数 m_{E1ij} ,而第二个针对 $m_{ij}(\emptyset)$ 的强度得到了mass函数 m_{E2ij} .这样,针对每一个冲突值,我们可以得到两个mass函数 m_{E1ij} 和 m_{E2ij} .

第三步:对 m_{E1ij} 和 m_{E2ij} 进行融合:

$$m_{Eij} = m_{E1ij} \otimes m_{E2ij}, i, j = 1, \dots, N, i \neq j \quad (2)$$

考虑 $m_{Eij}(\emptyset)$ 的出现是由于 $m_{ij}(\emptyset)$ 强度低,或者由短时间的强冲突导致的,所以在融合时我们将 $m_{Eij}(\emptyset)$ 的置信值转移到 $m_{Eij}(\text{YES})$:

$$m_{Eij}(\text{YES}) = m_{Eij}(\text{YES}) + m_{Eij}(\emptyset) \quad (3)$$

第四步:对于每个特征,我们可以得到其状态的置信值:

$$m_{\text{State}S_i}(H_i) = \frac{\sum_{\substack{j=1,\dots,N \\ j \neq i}} m_{E_{ij}}(H_i)}{N-1}, i = 1, \dots, N \quad (4)$$

由此,我们可以针对每个特征 S_i 的 mass 值得到其 pignistic 概率值:

$$\forall H_i \in \Theta \quad \text{State } S_i(H_i) = \sum_{\substack{A \in 2^\Theta \\ H_i \subset A}} \frac{1}{|A|} m_{\text{State } S_i}(A) \quad (5)$$

根据 $\text{State}S_i(\text{NO})$ 的数值可以评估特征 S_i 的异常程度. 当 $\text{State } S_i(\text{NO}) > \text{State } S_i(\text{YES})$ 时,认为特征 S_i 异常.

第五步:根据特征值的异常程度,计算折扣因子 α . 基本的原则是特征值异常的概率越高,则其可靠性越低. 例如,当 $\text{State } S_i(\text{NO}) = 1$ 时,则 $\alpha = 0$,即该特征信源完全不可靠;当 $\text{State } S_i(\text{NO}) = 0$ 时,则 $\alpha = 1$,即信源完全可靠. 具体方法见 3.2 节.

3.2 引入特征贡献度的折扣因子计算

不同证据源的可靠性不同,Shafer 根据可靠度对原始证据进行折扣处理,把折扣掉的信息分给未知焦元 Θ .

$$\begin{cases} m_i(A) = \alpha_i m_i(A), A \in 2^\Theta; A \neq \Theta \\ m_i(\Theta) = 1 - \alpha_i + \alpha_i m_i(\Theta) \end{cases} \quad (6)$$

其中 α_i 是特征 S_i 的可靠度又称折扣因子. 根据上一节的分析,冲突出现的强度以及持续的时间是判断特征异常的必要条件. 此外,还要考虑特征值对决策的贡献度. 相应的打折因子计算公式如下:

$$\alpha_i = \beta_i \frac{T_d - D_i^t}{T_d} \quad (7)$$

其中, $D_i^t = \sum_{k=t}^T \text{State } S_i(\text{NO})(k)$, T_d 为窗长. β_i 为特征贡献度,通过系统先验获得. 这样,我们根据得到的折扣因子就可以对不同传感器进行打折,再融合,得到最终的融合结果:

$$m_{\text{observ}}(t) = \alpha_1^t \cdot m_{S_1}(t) \otimes \alpha_2^t \cdot m_{S_2}(t) \otimes \dots \otimes \alpha_N^t \cdot m_{S_N}(t) \quad (8)$$

3.3 航路属性决策

传统的决策规则认为真实的目标的信任函数 $\text{Bel}(\cdot)$ 、似然函数 $\text{Pl}(\cdot)$ 以及 Pignistic 概率转换函数 $\text{BetP}(\cdot)$ 至少有一个应该取得最大值. 这三个函数定义如下:

$$\text{Bel}(A) = \sum_{A, B \in T^*; B \subseteq A} m(B) \quad (9)$$

$$\text{Pl}(A) = \sum_{A, B \in T^*; A \cap B \neq \emptyset} m(B) \quad (10)$$

$$\text{BetP}(A) = \sum_{A, B \in T^*; A \subseteq B} \frac{|A \cap B|}{|B|} m(B) \quad (11)$$

本文通过最大 Pignistic 概率对目标的航路属性进行决策,即航路属性 ID 为:

$$\text{ID} = \underset{i}{\text{argmax}} P_{\text{observ}}(H_i) \quad (12)$$

其中: $\forall H_i \in \Theta, P_{\text{observ}}(H_i) = \sum_{\substack{A \in 2^\Theta \\ H_i \subset A}} \frac{1}{|A|} m_{\text{observ}}(A)$

但是在近机场附近的复杂波区,以及在航路密集的区域不适合强行对目标进行分类^[13],为此考虑两种情况:

(1) 特征空间中不同目标相互重叠的区域,即不同目标的特征比较相似,强制分类可能会导致较大的错误. 其主要特征是基本信任函数值在几个目标中均匀分配,从而导致 $\text{Bel}(C_p)$ 和 $\text{Pl}(C_p)$ ($p = 1, 2, \dots, r$) 的值都比较接近,且最大值都比较小.

(2) 由于目标与所有航路的距离都比较大,那么其可能属于非航路目标或者杂波. 其主要表现为辨识空间上的基本信任函数值较大,而 $\text{Bel}(C_p)$ ($p = 1, 2, \dots, r$) 的最大值比较小,特别是当目标同时与多条航路的距离都很近且方向大致相同时, $\max_{C_p \in C} \text{Bel}(C_p)$ 将趋向于 0,而 $\max_{C_p \in C} \text{Pl}(C_p)$ 将趋向于 1. 由此制定如下“拒判”规则:

$$(1) \max_{C_p \in C} \text{Pl}(C_p) < \text{Pl}_{\min}$$

$$(2) \max_{C_p \in C} \text{Bel}(C_p) < \text{Bel}_{\min}$$

如果满足上述任意一条,则拒绝将目标分给任何航路. 其中 Bel_{\min} 和 Pl_{\min} 分别为信任函数值和似然函数值的门限值,系统设计者可以根据实际需要或经验值(误判率和拒判率的大小)来确定.

4 航路异常变化检测

在航路目标分类中,目标航迹由一系列点构成,可看作马尔科夫随机过程(MCM). 由此,我们可以将 MCM 得到的预测值与实际观测值进行比对,从而对目标类别属性变化进行检测和监控. 其过程分为四个阶段:

(1) 观测阶段

由式(9)我们可以得到 t 时刻的 mass 函数 $m_{\text{observ}}(t)$.

(2) 航迹航路预测阶段

根据 MCM 演变方程,在马尔科夫预测框架中, $\mathbf{V}_{\text{observ}}(t)$ 作为输入,是当前数据源的状态. 根据 pignistic 公式我们可以将 $m_{\text{observ}}(t)$ 转换为概率框架的向量 $\mathbf{V}_{\text{observ}}(t)$ 作为马尔科夫预测的观测概率集输入. 根据给定的马尔科夫转移矩阵 \mathbf{T} ,可以得到预测向量

$$\mathbf{V}_{\text{pred}}(t+1|t) = \mathbf{V}_{\text{observ}}(t) * \mathbf{T} \quad (13)$$

$\mathbf{V}_{\text{observ}}(t)$ 是 mass 集. 预测的概率集必须要转化为 mass 函数集. 若概率集是完备的,即 $\sum P_{\text{pred}}(H_i) = 1$,则可直接把概率集转化为贝叶斯 mass 函数的形式. 如果是

贝叶斯 mass 分布,那么在单假设集的概率值就可以直接被相应单假设集上的 mass 集取代. 即:

$$P_{\text{pred}}(H_i) \rightarrow m_{\text{pred}}(H_i) \quad (14)$$

(3) 融合阶段

通过使用 Smet's 的融合规则 \otimes , 我们可以对预测的 mass 值 m_{pred} 和观测到的 mass 函数值 m_{observ} 的融合, 即

$$m_{\text{fus}}(t+1) = m_{\text{pred}}(t+1 | t) \otimes m_{\text{observ}}(t+1) \quad (15)$$

$$m_{\text{fus}}(\emptyset)(t+1) = \sum_{A \cap B = \emptyset} m_{\text{pred}}(A)(t+1) \cdot m_{\text{observ}}(B)(t+1) \quad (16)$$

(4) 航路属性变化检测阶段

根据观测与预测 mass 函数值之间的冲突值 $m_{\text{fus}}(\emptyset)$ 来检测目标属性的异常变化. 实际中当存在异常变化时, 冲突值会迅速增加然后降低到残差值(由于马尔科夫预测的适应性导致的). 也就是说, 若发生了航路切换, 切换时刻冲突将会突然增大. 由此, 定义三个专家来对实时的冲突值进行判断.

专家 1: 评估两个连续冲突值之间的斜率, 斜率越大, 则目标行为更倾向于异常, 反之, 目标行为更倾向于正常, 而当斜率为 0 时, 也就是冲突值是恒定不变的. 计算公式如下:

$$E1(t) = \frac{m_{\text{fus}}(\emptyset)(t + \Delta t) - m_{\text{fus}}(\emptyset)(t)}{\Delta t} \quad (17)$$

专家 2: 评估两个连续冲突值之间的差值, 变化幅度越大, 则目标行为越倾向于异常, 反之, 目标行为更倾向于正常. 计算公式如下:

$$E2(t) = |m_{\text{fus}}(\emptyset)(t+1) - m_{\text{fus}}(\emptyset)(t)| \quad (18)$$

专家 3: 评估 N 个连续冲突值之间的方差值. 方差越大, 说明目标行为更可能是异常的, 反之, 目标行为更倾向于正常:

$$E3(t) = \frac{1}{2N+1} \sum_{i=0}^N [m_{\text{fus}}(\emptyset)(t \pm i)]^2 \quad (19)$$

综合三个专家的意见, 可以对短时间的高冲突进行检测. 三个专家的辨识框架 $\Theta_E = \{ \text{YES}, \text{NO} \}$, “YES” 表示目标的航路属性没有发生异常, “NO” 表示目标的航路属性发生了异常变化.

5 综合推理决策

通过对每个专家得到的 mass 函数进行融合, 我们可以得到最终的融合结果, 即:

$$m_E = m_{E1} \otimes m_{E2} \otimes m_{E3} \quad (20)$$

其中, $m_{E12} = m_{E1} \otimes m_{E2}$ 以及 $m_E = m_{E12} \otimes m_{E3}$.

若冲突值为负的并且很高或者为正且很低, 表示航路属性没有异常变化, 可将冲突值分配给“YES”, 即: $m_{E12}(\text{YES}) = m_{E12}(\text{YES}) + m_{E12}(\emptyset)$.

若冲突峰值很小或者持续增高或下降较长一段时间, 也表示没有异常, 同样的将冲突的 mass 值再分配给“YES”, 即: $m_E(\text{YES}) = m_E(\text{YES}) + m_E(\emptyset)$.

最后的根据 pignistic 概率极大化实现:

$$\text{Behavior} = \arg \max_i [P_E(H_i)] \quad (21)$$

$$\forall H_i \in \Theta, P_E(H_i) = \sum_{\substack{A \in \Theta \\ H_i \subset A}} \frac{1}{|A|} m_E(A) \quad (22)$$

如果说决策结果为“YES”, 即目标行为正常; 反之, 如果决策结果为“NO”, 则当前目标的行为发生了异常.

6 仿真分析

6.1 切换航路目标的检测

考虑三条航路: 航路 A_1 依次与航路 A_3 和 A_2 相交. 如图 2 所示, 空域中有一航路目标, 开始的时候沿着航路 A_1 飞行, 在第 26 帧与航路 A_2 相交处发生航路切换, 该航路变化 28 帧结束. 图中实线为航路, 虚线为量测, 点迹为卡尔曼滤波结果.




图2 航路目标仿真场景图(场景1)

利用文献[14]的基本置信指派构造方法, 可得目标的距离、弦长以及航向三个因子上属于各个航路的基本信任指派. 认为目标不可能在航路 1, 2, 3 之间发生切换, 也不可能由航路目标转换为非航路目标. 由此我们可以定义状态转移矩阵如下:

$$T = \begin{matrix} & \begin{matrix} A_1 & A_2 & A_3 & \emptyset \end{matrix} \\ \begin{matrix} A_1 \\ A_2 \\ A_3 \\ \emptyset \end{matrix} & \left\{ \begin{array}{cccc} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1/4 & 1/4 & 1/4 & 1/4 \end{array} \right\} \end{matrix}$$

图 3 给出了文献[15]所提的动态证据推理方法 (DER) 结果. 实线为 A_1 航线判定值, 虚线为 A_2 航线判定值, 两点虚线为 A_3 航线判定值, 圆点线为异常变化的判定值. 可以看出 DER 虽然判定正确, 但是航路 A_2 其判断有所波动. 且异常变化时间段从 25 帧到 30 帧都处于高值.





图3 DER方法结果(场景1)

采用本文提出的多特征融合算法,可以求得目标属于不同航路的 mass 值,采用 pignistic 概率转换式 (6),融合后的 pignistic 值以及决策结果如图 4 (a) 所示,其中,目标由于在第 26 帧左右发生航路切换,本文算法有效的识别了其在第 26 帧之前属于航路 A_1 以及之后切换到了航路 A_2 . TBMTFA 对目标进行异常检测结果如图 4 (b) 所示:上图展示了实际测得的与预测的 mass 值融合后得到的冲突值,可以看出,在第 25 帧左右,由观测得到的结果与预测结果产生了很大的冲突;中图可以看出专家最后融合结果显示在 25 帧左右目标属性发生了异常变化;该组实验表明,在交叉场景下 TBM 方法的时间判定比 DER 方法精确. 下图展示了最终的检测结果.


6.2 偏离-回归航路

如图 5 所示,假设在给定区域内,一共存在三条航路 A_1, A_2 和 A_3 . 有一航路目标开始的时候沿着航路 A_1 飞行,稳定飞行至 25 帧时偏离了航路 A_1 , 29 帧又回到了航路 A_1 .

DER 方法检测结果如图 6 所示,DER 方法未能准确判断目标在 29 帧回归航路,甚至在 30 帧时还有判定值的下降趋势. 在异常检测方面,在异常行为已经结束的时候依然具有较高的异常判定值,这是因为其内部的置信参数只随时刻变化,没有考虑目标在一段时间内的情况变化. 采用本文提出的多特征融合算法的融合后 pignistic 值以及决策结果如图 7 (a) 所示. 目标由于在第 25 帧偏离了航路 A_1 , 29 帧回归 A_1 航路,因此在 29 帧本文方法判定航路为 A_1 . TBMTFA 对目标进行异常检测结果如图 7 (b) 所示:上图显示在第 25 帧左右开始,由观测得到的结果与预测结果产生了很大冲突;中图显示在 25 帧左右目标属性发生了异常变化;下图说明了本文算法可有效地检测出目标航路属性的异常变化.



(a) TBMTFA航路属性决策结果(场景1)



(b) TBMTFA异常检测结果(场景1)

图4 TBMTFA方法结果(场景1)




图5 航路目标仿真场景图(场景2)




图6 DER方法结果(场景2)

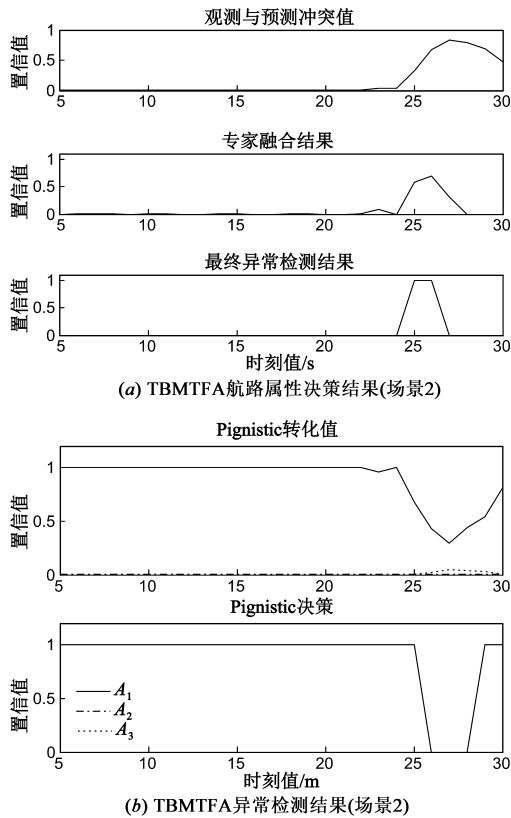


图7 TBMTFA航路方法结果(场景2)

7 结论

针对在航迹分类中变航路的异常目标检测问题,本文提出了一种基于TBM的双层融合框架,并通过对时间序列上对预测值与观测值进行融合,建立专家系统分析其冲突值以实现目标异常属性变化的检测。此外,通过分析多特征融合结果之间的冲突,计算其可靠程度,得到折扣因子,从而对不同特征的指派进行打折后再融合,并实现了目标的航路属性识别。最后,通过切换航路异常目标检测以及偏离-回归航路异常目标检测场景的仿真实验,与DER方法相比,本文方法能够更加精确的确定异常发生时刻,且在偏离-回归场景下依然能够准确判定航路属性。

参考文献

- [1] T Hossein, S Mita. Multi-sensor data fusion for autonomous vehicle navigation through adaptive particle filter [A]. IEEE Intelligent Vehicles Symposium [C]. San Diego, CA, USA: IEEE, 2010. 752 – 759.
- [2] 王增福, 潘泉, 陈丽平, 等. 基于航路-航迹关联的天波超视距雷达航迹分类 [J]. 系统工程与电子技术, 2012, 34(10): 2018 – 2022
Wang Zengfu, Pan Quan, Chen Liping, et al. Tracks classification based on airway-track association for over-the-horizon radar [J]. Systems Engineering and Electronics, 2012, 34(10): 2018 – 2022. (in Chinese)

- [3] M Grabisch, H Prade. The correlation problem in sensor fusion in a possibilistic framework [J]. International Journal of Intelligent Systems, 2001, 16(11): 1273 – 1283.
- [4] T Huhnagen, I Dengler, A Tamke, et al. Maneuver recognition using probabilistic finite-state machines and fuzzy logic [A]. IEEE Intelligent Vehicles Symposium [C]. San Diego, CA, USA: IEEE, 2010. 65 – 70.
- [5] A Ayoun, P Smets. Data association in multi-target detection using the transferable belief model [J]. International Journal of Intelligent Systems, 2000, 16(10): 1167 – 1182.
- [6] P Smets. The application of the transferable belief model to diagnostic problems [J]. International Journal of Intelligent Systems, 1998, 13(2–3): 127 – 157.
- [7] A Debiolles, L Oukhellou, T Denoeux, P Akin. Output coding of spatially dependent subclassifiers in evidential framework. Application to the diagnosis of railway track/vehicle transmission system [A]. 9th International Conference on Information Fusion [C]. Florence, Italy: IEEE, 2006. 1 – 6.
- [8] T Denoeux, G Govaert. Combined supervised and unsupervised learning for system diagnosis using Dempster-Shafer theory [A]. IMACS Multi-conference, Computational Engineering in Systems Applications. Symposium on Control, Optimization and Supervision [C]. Lille, France: CESA, 1996. 104 – 109.
- [9] R Sadiq, H Najjaran, Y Kleiner. Investigating evidential reasoning for the interpretation of microbial water quality in a distribution network [J]. Stochastic Environmental Research and Risk Assessment, 2006, 21(1): 63 – 73.
- [10] O Mengshoel, A Darwiche, S Uckun. Sensor validation using bayesian networks [A]. 9th International Symposium on Artificial Intelligence, Robotics, and Automation in Space [C]. Los Angeles, CA, USA: i – SAIRAS, 2008.
- [11] Si X S, Hu C H, Yang J B, et al. On the dynamic evidential reasoning algorithm for fault prediction [J]. Expert Systems with Applications, 2011, 38(5): 5061 – 5080.
- [12] Denoux T, El Zoghby N, Cherfaoui V, et al. Optimal object association in the Dempster-Shafer framework [J]. IEEE Transactions on Cybernetics, 2014, 44(12): 2521 – 2531.
- [13] 王壮, 郁文贤, 庄钊文, 等. C~3I系统中的目标综合识别技术 [J]. 系统工程与电子技术, 2001, 23(1): 5 – 8.
Wang Zhuang, Yu Wenxian, Zhuang Zhaowen, et al. Fusion of multi-Source information for target identity estimation in C~3I system [J]. Systems Engineering and Electronics, 2001, 23(1): 5 – 8. (in Chinese)

- [14] 李立,王文旭,梁彦. 基于动态证据推理的异常航路目标检测[J]. 电子设计工程,2015,23(9):30-33
Li Li, Wang Wenxu, LIANG Yan. The detection of abnor-

mal airline targets based on evidence theory[J]. Electronic Design Engineering, 2015, 23(9):30-33. (in Chinese)

作者简介



王晓华 女,1986年3月出生. 博士研究生. 模式识别与智能系统专业,主要研究方向航迹规划、信息融合.
E-mail: xiaohuawang311@sina.com



邹杰 男,1977年1月出生. 系统工程专业,高级工程师,光电控制技术重点实验室. 主要研究方向为火控系统工程、智能控制、信息融合等技术研究.
E-mail: zoujie@163.com



李立 女,1991年1月出生于河南. 硕士研究生. 信息融合,证据推理.
E-mail: lilynwpu@mail.nwpu.edu.cn



梁彦(通信作者) 男,1971年生,博士生导师. 主要研究方向为估计理论,信息融合.
E-mail: liangyan@nwpu.edu.cn