

贝叶斯网融合模型的机载多传感器性能评估^①陈志刚^{②*} 李 贤^{③*} 徐世友^{**} 娄小平^{*}

(* 中南大学信息科学与工程学院 长沙 410083)

(** 国防科技大学 ATR 实验室 长沙 410073)

摘 要 对贝叶斯网融合模型的机载多传感器性能评估进行了研究。首先对机载传感器的特性进行了分析,利用专家知识进行网络建模。给出了一种利用本地混淆矩阵(LCM)和 K 次测量进行计算得出的全局混淆矩阵(GCM)计算方法,随后又给出了一种利用 K 次 GCM 和 LCM 迭代计算 $K+1$ 次 GCM 的计算方法。给出一些性能指标并利用迭代计算方法对模型分别进行了目标属性未知、目标属性为我、目标属性为敌三种场景下各传感器性能计算,对结果进行了分析并和真实值进行了比较分析,证明了结果的准确性。

关键词 性能评估,机载平台,迭代计算,贝叶斯网

0 引 言

在多传感器信息融合系统中,各传感器提供的信息一般是不完整、不精确、模糊的,信息融合中心不得不依据这些不确定性信息进行推理,以达到目标身份识别和属性判决的目的。可以讲,不确定性推理是目标识别和属性信息融合的基础,而一般的不确定性推理模型有 Bayes 方法、D-S 证据理论、模糊积分等,每个模型的推理规则不一样,从而基于某种推理模型的各传感器对最终判决结果的影响是不一样的。

贝叶斯网络(Bayesian networks)是用来表示变量间概率依赖关系的图形模式。是目前人工智能领域解决不确定性知识表达和复杂概率推理问题的有效理论模型。它以带有概率注释的有向无环图的形式定性而且定量地表示了变量间的依赖关系,从而实现了对变量集合概率分布的建模^[1-3]。用贝叶斯网推理模型时我们往往很想知道:各个传感器对最终的判决结果的影响如何?在多传感器系统中是否应该加入此传感器?此传感器的效能如何?对于以上问题目前国外有一些文献在理论方面和应用方面进行了研究探讨^[4,5],在国内,也有一些文献进行了相关研究^[6],但以机载多传感器系统为平台进行整

体性能评估的文献比较少,本文将以机载多传感器系统为平台来研究融合系统的性能情况,以及在没有实际测量的情况下对系统性能进行推算。

1 贝叶斯网推理

1.1 贝叶斯理论

贝叶斯网络是一种能够帮助人们将概率统计应用于复杂领域,进而进行不确定性推理和数据分析的方法。它能够系统地描述某一事件中各随机变量之间的关系,进而计算某些事件发生的概率^[7,8]。其主要原理是:

设先验概率为 $P(h)$,通过试验获得的观测为 E ,则下面公式:

$$P(h|E) = \frac{P(E|h)P(h)}{P(E)} \quad (1)$$

其中:

$$P(E) = \begin{cases} \sum_h P(E|h)P(h) & (h \text{ 是不连续的}) \\ \int_h P(E|h)P(h)dh & (h \text{ 是连续的}) \end{cases} \quad (2)$$

若对同一假设事件从两个信息源获得的证据为

① 国家自然科学基金(61073186),国家自然科学基金委员会国际(地区)合作与交流(61111140391)资助项目。

② 男,1964年生,博士,教授;研究方向:传感器分布式网络;E-mail:czg@mail.csu.edu.cn

③ 通讯作者;E-mail:lx20010@gmail.com

(收稿日期:2012-09-21)

E_1 和 E_2 , 则综合观测的概率为

$$P(h|E_1, E_2) = \frac{P(E_1, E_2|h)P(h)}{P(E_1, E_2)} \quad (3)$$

一般情况下假设 E_1 和 E_2 相互独立, 则式(3)可变为

$$P(h|E_1, E_2) = \frac{P(E_1|h)P(E_2|h)P(h)}{P(E_1)P(E_2)} \quad (4)$$

其中 E_1 和 E_2 的独立性假设在敌我识别时的很多情形下是合理的, 例如利用雷达和敌我识别器进行目标敌我识别时, 两者的观测显然是独立的。

贝叶斯理论的组合方式具有依次累加合成的性质, 实质上是不断更新的“先验概率”与随后到来的数据进行组合, 以得到重新更新的“先验概率”过程。因此贝叶斯理论的核心就是利用观测对概率进行不断更新^[9,10]。

1.2 贝叶斯网络

从概率论的角度分析, 综合敌我识别的过程实际上是求解条件概率 $P(h_i|E_1, E_2, \dots, E_n)$ 的过程, 其中 $E_1, E_2, \dots, E_n$ 代表多个传感器观测得到的与目标敌我属性相关的信息(证据), h_i 代表目标可能的身份信息^[11]。简单的贝叶斯推理很难满足综合敌我识别这种层次化、异质、异类的识别过程, 因此本文利用贝叶斯网络进行综合敌我识别。

贝叶斯网络又称信度网络, 是概率论和图论相结合的产物, 是目前人工智能领域解决不确定性知识表达和复杂概率推理问题的有效理论模型^[12]。贝叶斯网络通过变量间的条件独立性可以将联合分布分解为多个复杂度较低的概率分布, 从而降低模型的复杂性, 提高推理效率^[13]。

2 机载传感器贝叶斯网融合模型

2.1 融合模型构建方法

一般情况下有三种不同的方式来构造贝叶斯网:(1)数据驱动的方式, 由领域专家确定贝叶斯网络的节点, 通过大量的训练数据, 来学习贝叶斯网的结构和参数;(2)半数据驱动的方法, 由领域专家确定贝叶斯网络的节点, 通过专家的知识来指定网络的结构, 而通过机器学习的方法从数据中学习网络的参数;(3)通过专家知识构建, 由领域专家确定贝叶斯网的变量节点, 然后通过专家的知识来确定贝

叶斯网络的结构, 并指定它的分布参数。由于机载多传感器平台实际应用中一般不会有大量完备的训练数据给出, 往往对应一些目标我们没有任何的先期实测数据, 所以将通过专家知识进行网络模型的构建^[14,15]。

2.2 传感器节点确定

在机载多传感器平台上, 我们最主要的目的是进行敌我识别, 所以配备了较多的敌我识别传感器, 配备的敌我识别类传感器以及对应的信息识别能力见表 1。

表 1 敌我识别类传感器

传感器	识别信息
IFF + ADS - B	敌、我、中立、民用
欺骗式询问	敌不明

除了用来进行敌我识别的传感器, 还包括一些获取目标其他信息如目标大小、目标辐射源类型等的传感器, 具体见表 2。

表 2 其他类传感器

传感器	识别信息
HRRP	目标类型如 J10、SU27、F16、F15、HY2000、A320、737、F18
JEM 调制信息	目标平台特性如单螺旋桨、双螺旋桨、喷气式
IR	目标类型如 J10、SU27、F16、F15、HY2000、A320、737、F18
ESM	辐射源类型如: 1473、N001、AGP68、AGP63、RDY2、WXR700X、AGP79

2.3 融合模型的构建

图 1 为贝叶斯网络模型。从上述分析可以看出在贝叶斯网络中有两个核心中心, 分别为目标类型和敌我属性。因此本文采用中心—辐射的构造方式, 分别以目标类型、目标敌我属性两个中心, 构建各自的贝叶斯网络, 然后将两个贝叶斯网络合并, 进行独立性分析, 最后针对具体情况调整边的方向。最后建模的模型如图 1 所示。




图1 贝叶斯网模型

3 基于贝叶斯融合模型的性能评估推理

3.1 全局混淆矩阵(GCM)计算

定义目标类型 $T = \{t_1, t_2, \dots, t_n\}$, 其中 t_n 表示第 n 类目标。目标类型的先验概率用 $P_0(T = t_i) = P_0(t_i)$ 来表示。对一个传感器 S , 输出结果为 $O^s = \{o_1^s, o_2^s, \dots, o_{m_s}^s\}$ 中的一个或多个独立测量结果。

定义本地混淆矩阵 (local confusion matrix, LCM) 为 $A^s = [a_{ij}^s]_{n \times m_s}$, 其中 a_{ij}^s 表示传感器 s 的输出结果为 $o_j \in O^s$ 是对应目标类型 t_j 时的概率。

定义 $y_{1:k} = \{y_1, y_2, \dots, y_k\}$ 表示一个 LCM 为 $A = [a_{ij}]_{n \times m}$ 的传感器连续测量 k 次后的 k 个结果^[15]。

设目标真实类别为 t_i , 通过特定的 k 次测量 $y_{1:k}$, 分类而得到的类别 t_j , 那么就有:

$$P(t_j | y_{1:k}, t_i) \propto P(y_{1:k} | t_j) = \prod_{i=1}^k P(y_i | t_j) \quad (5)$$

对于任意的 k 次测量就有

$$\begin{aligned} E[P(t_j | t_i)] &= \sum_{y_{1:k}} P(t_j, y_{1:k} | t_i) \\ &= \sum_{y_{1:k}} P(t_j | y_{1:k}) P(y_{1:k} | t_i) \end{aligned} \quad (6)$$

定义全局混淆矩阵 (global confusion matrix, GCM) 为一个 $n \times n$ 的矩阵 G_k , 其中 G_k 的第 i 行表示通过任意 k 次测量 r_i 目标被识别为 $c_j (0 \leq j = \text{ColumnNumber}) \leq n$) 类型的概率, G_k 的计算如下:

$$\begin{aligned} g_{ij}^k &= \sum_{y_{1:k}} P(t_j | y_{1:k}, t_i) P(y_{1:k} | t_i) \\ &= \sum_{y_{1:k}} \frac{\prod_{c=1}^k P(y_c | j) P(y_c | i)}{\sum_t P_0(t) \prod_{c=1}^k P(y_c | t)} P_0(t_j) \end{aligned} \quad (7)$$

其中 $P_0(t_j)$ 表示先验概率。

式(7)为 GCM 的一般计算式, 接下来介绍一种计算 GCM 的 g_{ii}^k 简化迭代计算。

3.2 GCM 迭代计算

定理 1: GCM 中关于对角线对称元素 g_{ij}^k 和 g_{ji}^k 的比值等于先验概率 $P_0(t_j)$ 和 $P_0(t_i)$ 的比值, 即 $P_0(t_i) g_{ij}^k = P_0(t_j) g_{ji}^k$ 。

证明:

$$\begin{aligned} g_{ij}^k &= \sum_{y_{1:k}} P(t_j | y_{1:k}) P(y_{1:k} | t_i) \\ &= \sum_{y_{1:k}} \left[\frac{P(y_{1:k} | t_j) P_0(t_j)}{P(y_{1:k})} \right] \left[\frac{P(t_i | y_{1:k}) P(y_{1:k})}{P_0(t_i)} \right] \\ &= \frac{P_0(t_j)}{P_0(t_i)} \sum_{y_{1:k}} P(t_i | y_{1:k}) P(y_{1:k} | t_j) = \frac{P_0(t_j)}{P_0(t_i)} g_{ji}^k \end{aligned} \quad (8)$$

这个定理的意义在于一旦知道了 g_{ii}^k 和 $g_{ij}^k (j > i)$ 就可以求得整个 GCM。根据之前的推理可知

$$\begin{aligned} g_{ii}^k &= \sum_{y_{1:k}} P(t_i | y_{1:k}) P(y_{1:k} | t_i) \\ &= \sum_{y_{1:k}} \frac{P(y_{1:k} | i)^2}{P(y_{1:k})} P_0(t_i) \\ &= \sum_{y_{1:k}} \frac{\prod_{c=1}^k P(y_c | i)^2}{\sum_t P_0(t) \prod_{c=1}^k P(y_c | t)} P_0(t_j) \end{aligned} \quad (9)$$

设 α_i 表示在第 k 次测量中观测节点输出为 o_i 的个数, 显然有 $\alpha_1 + \alpha_2 + \dots + \alpha_m = k$, 那么在 k 次测量中得到相同的 α 序列即 $(\alpha_1, \alpha_2, \dots, \alpha_m)$ 的概率为 $\frac{k!}{\alpha_1! \alpha_2! \dots \alpha_m!}$, 最终 g_{ii}^k 表达式可写为

$$\begin{aligned} g_{ii}^k &= \sum_{\alpha_1=0}^k \sum_{\alpha_2=0}^{k-\alpha_1} \dots \sum_{\alpha_{m-1}=0}^{k-(\alpha_1+\dots+\alpha_{m-2})} \frac{k!}{\alpha_1! \alpha_2! \dots \alpha_m!} \\ &\quad \times \frac{\prod_{j=1}^m (a_{ij})^{2\alpha_j}}{\sum_t P_0(t) \prod_{j=1}^m (a_{ij})^{\alpha_j}} P_0(t_i) \end{aligned} \quad (10)$$

根据式(10)给出一个通过 g_{ii}^k 简化递归算法来计算 g_{ii}^{k+1} , 在这之前需要进行一些定义。

①给一组正数 $\{\alpha_i\}_1^m$, 其中有 $\sum_{j=1}^m \alpha_j = k$, 那么定义 $(m-1)$ 维向量 $[\alpha_1, \alpha_2, \dots, \alpha_{m-1}]$ 为 $\vec{\alpha}$, 定义 $\vec{\alpha}_{\oplus} = \sum_{r < m} \alpha_r = k - \alpha_m$

②多项式 $\binom{k}{\alpha_1, \alpha_2, \dots, \alpha_{m-1}, k - \vec{\alpha}_{\oplus}}$ 可写为 $\binom{k}{\vec{\alpha}, k - \vec{\alpha}_{\oplus}}$ 。

③定义 δ_j 为 $m-1$ 维向量, 其中第 j 位为 1 其他位为 0, 即 $\delta_j = [0, 0, \dots, 1, \dots, 0]_{m-1}$, 那么有

$$\begin{aligned} g_{ii, \vec{\alpha}}^k &= \sum_{\alpha_m=0}^k \cdot \sum_{\forall \vec{\alpha}; \vec{\alpha}_{\oplus} = k - \alpha_m} g_{ii, \vec{\alpha}}^k \\ &= \binom{k}{\vec{\alpha}, k - \vec{\alpha}_{\oplus}} \\ &\times \frac{(a_{im})^{2(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} (\alpha_j)^{2\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} (a_j)^{\alpha_j}} P_0(i) \end{aligned} \quad (11)$$

根据上式就有:

$$\begin{aligned} g_{ii, \vec{\alpha}}^{k+1} &= \binom{k+1}{\vec{\alpha}, k+1 - \vec{\alpha}_{\oplus}} \\ &\times \frac{(a_{im})^{2(k+1 - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} (\alpha_j)^{2\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k+1 - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} (a_j)^{\alpha_j}} P_0(i) \\ &= (a_{im})^2 \binom{k+1}{\vec{\alpha}, k+1 - \vec{\alpha}_{\oplus}} \\ &\times \left[\frac{P_0(t_i) (a_{im})^{2(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{2\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}} \right] \\ &\times \left[\frac{\sum_{t=1}^n P_0(t) (a_{im})^{(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k+1 - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}} \right] \\ &= (a_{im})^2 \binom{k+1}{\vec{\alpha}, k+1 - \vec{\alpha}_{\oplus}} g_{ii, \vec{\alpha}}^k \\ &\times \left[\frac{\sum_{t=1}^n P_0(t) (a_{im})^{(k - \vec{\alpha}_{\oplus})} (\sum_{p=1}^m a_p) \prod_{j=1}^{m-1} a_j^{\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k+1 - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}} \right] \\ &(\because \sum_{p=1}^m a_p = 1) \\ &= (a_{im})^2 \binom{k+1}{\vec{\alpha}, k+1 - \vec{\alpha}_{\oplus}} g_{ii, \vec{\alpha}}^k \\ &\times \left[1 + \sum_{p=1}^{m-1} \frac{\sum_{t=1}^n P_0(t) (a_p) (a_{im})^{(k - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}}{\sum_{t=1}^n P_0(t) (a_{im})^{(k+1 - \vec{\alpha}_{\oplus})} \prod_{j=1}^{m-1} a_j^{\alpha_j}} \right] \end{aligned}$$

$$\begin{aligned} &= (a_{im})^2 \binom{k+1}{\vec{\alpha}, k+1 - \vec{\alpha}_{\oplus}} g_{ii, \vec{\alpha}}^k \\ &\times \left[1 + \sum_{p=1}^{m-1} \frac{(k+1 - \vec{\alpha}_{\oplus})}{(\alpha_p + 1)} \left(\frac{a_p}{a_{im}} \right)^2 \frac{g_{ii, \vec{\alpha}}^{k+1}}{g_{ii, \vec{\alpha} + \delta_p}^{k+1}} \right] \Rightarrow \frac{1}{g_{ii, \vec{\alpha}}^{k+1}} \\ &= \frac{(k+1 - \vec{\alpha}_{\oplus})}{(a_{im})^2} \\ &\times \left[\frac{1}{(k+1)} \cdot \frac{1}{g_{ii, \vec{\alpha}}^k} - \sum_{p=1}^{m-1} \frac{(a_p)^2}{(a_p + 1)} \cdot \frac{1}{g_{ii, \vec{\alpha} + \delta_p}^{k+1}} \right] \end{aligned} \quad (12)$$

式(12)即为 g_{ii}^{k+1} 的迭代计算公式。

4 实验及分析

对网络的评估主要是对敌我属性节点即 Enemy_Ally_Neutral_Civil 进行性能评估, 我们将考虑对目标情况完全未知、目标已知为我、目标已知为敌的三种情况下各传感器性能情况, 并将预估准确率和仿真准确率进行对比证明本算法的准确性。

4.1 属性未知情况下性能评估

如表 3 所示, 设类型节点的先验概率为均分概率, 表示对目标敌我属性完全未知的情况。

表 3 属性未知下先验概率

敌	我	中立	民用
0.25	0.25	0.25	0.25

在给出结果之前先给出以下指标的定义:

PCC(probability of correct classification): 表示对所有类型的正确分类的概率。通过对 GCM 对角线上的值求平均得到, 用来反映整个模型的性能。

MPCC(marginal PPC): 在证据节点集中由非此证据节点计算得到的正确分类率。

IPCC(individual PCC): 在证据节点集中由特定某证据节点计算得到的正确分类率。通过此指标衡量此特定证据节点的单独重要性。

MI(marginal improvement): 选用此证据节点所带来的性能提升, 其计算公式为 $MI = PCC - MPCC$ 。通过此指标来衡量此证据节点对整个网络模型的重要性。

通过计算得出如表 4 所示的结果:

表4 属性未知时性能表

证据节点数	证据节点类型	PCC(%)	MPCC(%)	IPCC(%)	MI(%)
1	IFF + ADS - B	71.38	25	71.38	46.38
2	IFF + ADS - B	71.62	26.74	71.13	44.88
	欺骗询问		71.13	26.74	0.49
3	IFF + ADS - B	81.47	70.04	71.13	13.68
	欺骗询问		83.13	26.75	0.59
	ESM		71.64	68.94	12.09
4	IFF + ADS - B	86.45	76.04	71.27	13.59
	欺骗询问		89.28	26.71	0.35
	ESM		79.68	68.94	9.95
	JEM 调制		83.75	57.45	5.88
5	IFF + ADS - B	93.14	84.25	71.15	8.89
	欺骗询问		92.77	26.73	0.37
	ESM		88.53	69.05	4.61
	JEM 调制		90.64	57.48	2.5
	HRRP		89.63	63.89	3.52
6	IFF + ADS - B	95.63	88.59	71.24	7.04
	欺骗询问		95.13	26.71	0.5
	ESM		93.24	68.96	2.39
	JEM 调制		94.04	57.58	1.59
	HRRP		93.69	63.66	1.94
	IR		93.1	69.55	2.53

通过以上计算我们可以发现传感器的增加可以提高分类准确性,其中 IFF + ADS - B、ESM、IR 对整体性能的提高都有着重要影响,贡献率分别为 7.04%、2.39%、2.53%。

4.2 属性为我情况下性能评估

设类型节点的先验概率如表 5 所示,表示已知目标敌我属性通过 IFF + ADS - B 识别为了我的情况。

表5 属性为我下先验概率

敌	我	中立	民用
0.016	0.95	0.017	0.017

在这种先验概率设置情况下,显然平均分类准确性会降低,但我们更关注其他传感器的加入对我方目标识别的准确情况,在此先定义如下指标:

APPC(Ally probability correct classification):我

方目标分类准确性,此值为混淆矩阵中我方分类率的那个值。

IAP(Improvement of ally probability):表示对我方目标分类准确性整体性能的提升,其计算方法为 $IAP = APPC - P_{ally}$, 其中 $P_{ally} = 0.95$ 表示我方目标的先验概率。

AIPPC_i(Individual APPC):表示单独用 i 传感器的分类准确度。

IAP_i(Improvement of ally probability by i):表示通过 i 传感器而带来的对我方目标分类准确性的性能提升。

通过计算得出如表 6 所示的结果。

通过以上计算我们可以发现传感器的增加同样可以提高分类准确性,由于 IFF + ADS - B 本身识别准确率已经很高了,其他传感器贡献度都不大,而整体性能的提升比较缓慢,最终的提升才 4.68%。

表 6 属性为我时性能表

证据节点个数	证据节点类型	APPC(%)	AIPPC _i (%)	IAP(%)	IAP _i (%)
1	欺骗询问	95.03	95.03	0.03	0.03
2	欺骗询问	96.35	96.25	1.35	0.1
	ESM				1.32
3	欺骗询问	98.17	95.73	3.17	0.03
	ESM				2.41
	JEM 调制				1.83
4	欺骗询问	99.04	95.98	4.04	0.02
	ESM				1.14
	JEM 调制				0.59
	HRRP				0.85
	欺骗询问				0.06
5	ESM	99.68	96.27	4.68	0.68
	JEM 调制				0.41
	HRRP				1
	IR				1.24

4.3 属性为敌情况下性能评估

设类型节点的先验概率如表 7,表示已知目标敌我属性通过 IFF + ADS - B 识别为了敌的情况。

表 7 属性为敌时先验概率

敌	我	中立	民用
0.8	0.06	0.07	0.07

在这种先验概率设置情况下,显然平均分类准确性会降低,但我们更关注其他传感器的加入对敌方目标识别的准确情况,在此先定义如下指标:

EPPC(Enemy probability correct classification):我方目标分类准确性,此值为混淆矩阵中我方分类率的那个值。

IEP(Improvement of enemy probability):表示对我方目标分类准确性整体性能的提升,其计算方法为 $IEP = EPPC - P_{\text{enemy}}$,其中 $P_{\text{enemy}} = 0.8$ 表示我方目标的先验概率。

EIPPC_i(Individual EPPC):表示单独用 i 传感器的分类准确度。IEP_i(Improvement of enemy probability by i):表示通过 i 传感器而带来的对我方目标分类准确性的性能提升。

通过计算得出如表 8 所示的结果。(空白表示上面已算出)

通过以上计算我们可以发现传感器的增加同样可以提高分类准确性,由于 IFF + ADS - B 本身识别准确率不是很高,其他传感器有较大贡献度,而整体性能最终提升 16.57%。

4.4 预估准确率和仿真准确率比对

将通过仿真平台得出的准确率视为真实值,而将预估算式得出的准确率视为估计值,定义为估计误差 $\Delta P = \text{真实值} - \text{估计值}$,可得图 2 所示的估计误差。




图 2 估计误差

表8 属性为敌时性能表

证据节点个数	证据节点类型	EPPC(%)	EIPPC _i (%)	IEP(%)	IEP _i (%)
1	欺骗询问	81.48	81.48	1.48	1.48
2	欺骗询问	89.63	88.87	9.63	0.67
	ESM				8.15
3	欺骗询问	93.28	85.97	13.28	0.33
	ESM				6.2
	JEM 调制				3.6
4	欺骗询问	95.27	87.4	15.27	0.19
	ESM				2.68
	JEM 调制				1.39
	HRRP				1.96
	欺骗询问				0.21
5	ESM	96.57	88.7	16.57	1.36
	JEM 调制				0.8
	HRRP				1.02
	IR				1.27

通过图2可见,所有 ΔP 都保持在一个较小值,说明了我们计算的正确性和有效性,并且可以计算出 $Mean(\Delta P_{\text{属性未知}}) = 3.51315\%$, $Mean(\Delta P_{\text{属性为敌}}) = 2.906\%$, $Mean(\Delta P_{\text{属性为我}}) = 1.49951\%$,说明如果起始准确度越大, ΔP 均值就越小,即预测精度越高。

5 结 论

本文对基于贝叶斯融合模型的融合系统的性能估计提出了一种基于统计的迭代计算方法,此方法通过计算全局混淆矩阵(GCM)的方式来得出对每种类型的分类准确率,通过此方法可以不经实际测量来估计整个系统的分类准确度,为融合系统的构建、传感器的取舍提供一个重要的评判指标。通过后面的实验分析,可以看出每个传感器的性能情况与性能贡献情况,为我们评判系统性能和各传感器性能提供重要依据,通过将仿真值与预估值比对证明了本方法的正确性和有效性。

参考文献

- [1] Pearl J. Fusion, propagation and structuring in belief Networks. *Artificial Intelligence*, 1986, 29(3): 241-288
- [2] Neapolitan R E. Learning Bayesian networks. New York: Pearson Prentice Hall Upper Saddle River, 2004. 32-48
- [3] 张连文, 郭海鹏. 贝叶斯网引论. 北京: 科学出版社, 2006. 113-117
- [4] Chang K C, Liggins M, Song Y. Fusion performance modeling for distributed tracking and fusion. In: Proceedings of the 6th International Conference on Information Fusion 2003, Queensland, Australia, 2003. 567-574
- [5] Chang K C, Sivaraman E, Liggins M. Performance modeling for multisensor tracking and classification. In: Processing of SPIE Defense and Security Symposium, Orlando, Florida, 2004, (5429): 335-342
- [6] Guo H W, Shi W K, Deng Y. Evaluating sensor reliability in classification problems based on evidence theory. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*, 2006, 36(5): 970-981
- [7] Yan L J, Cercone N. Bayesian network modeling for evolutionary genetic structures. *Computers and Mathematics with Applications*, 2010, 59: 2541-2551
- [8] Attias H. A variational Bayesian framework for graphical models. *Machine Learning*, 1999, 37(2): 183-233
- [9] Langseth H, Nielsen T D. Fusion of domain knowledge with data for structural learning in object oriented domain. *Machine Learning Research*, 2004, 4(3): 339-368
- [10] Bangs O. Object oriented Bayesian networks. Aalborg: Aalborg University, 2004. 56-87
- [11] Lam W, Nacchus F. Using new data to refine a Bayesian network. In: Processing of the 10th Conference on Uncertainty in Artificial Intelligence, Seattle, USA, 1994. 383-

390

- [12] Buntine W. Theory refinement on bayesian networks In: Processing of the 7th Conference on Uncertainty in Artificial Intelligence, Los Angeles, USA, 1991. 52-60
- [13] 王勇,代桂平,候亚荣等. 基于贝叶斯网络的组合服务信度评估方法. 高技术通讯, 2010. 20(1): 21-25
- [14] 周忠宝. 基于贝叶斯网络的概率安全评估方法及应用

研究[博士学位论文]. 长沙:国防科技大学, 2006. 132-165

- [15] Cooper G F, Herskovits E. A Bayesian method for constructing Bayesian belief networks from databases. In: Proceedings of the 7th Conference on Uncertainty in Artificial Intelligence, Morgan Kaufmann, USA, 1991. 86-94

Multi-sensors fusion performance assessment of airborne based Bayesian network fusion model

Chen Zhigang^{*}, Li Xian^{*}, Xu Shiyu^{**}, Lou Xiaoping^{*}

(^{*} School of Information Science and Engineering, Central South University, Changsha 410083)

(^{**} ATR Key Laboratory, National University of Defense Technology, Changsha 410073)

Abstract

Multi-sensors fusion performance assessment of airborne based Bayesian network fusion models was researched. Firstly, the net model was built with expert knowledge after the behaviors of airborne sensors were analyzed. Then, the method for calculating the global confusion matrix (GCM) was given by the calculation with the local confusion matrix (LCM) and k measurements, followed by the method for calculating the GCM of $k + 1$ with the i iterative calculation of LCM and GCM. Some performance indicators were given, and the iterative calculations for the sensors performance under such three scenes, target is unknown, target is ally, target is enemy, were conducted. The results were comparatively analyzed with true values, and the accuracy of the results were verified.

Key words: performance assessment, airborne platform, iterative calculate, Bayesian network