

# 广义证据推理融合结构

黄心汉, 李 鹏, 王 敏

(华中科技大学 控制科学与工程系, 湖北 武汉 430074)

**摘 要:**针对 Dempster-Shafer 理论(DST)及 Dezert-Smarandache 理论(DSmT)难以处理不确定信息的问题,定义了辨识框架中的不确定因子,提出了2种自适应通用分配法则(AUPR).并提出了证据理论的广义融合框架,并在此基础上构建了广义证据推理机.以 Pioneer 2-DXe 机器人为实验平台,绘制了实验场景的信度分布图.实验结果验证了所提方法的有效性和实用性,为构建统一的信息融合框架提供了有力的依据.

**关键词:**证据推理;融合框架;地图构建;信息融合

**中图分类号:**TP242.6 **文献标志码:**A **文章编号:**1673-4785(2010)06-0487-05

## General evidence reasoning fusion structure

HUANG Xin-han, LI Peng, WANG Min

(Dept. of Control Science & Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract:** In order to solve the problem of the Dempster-Shafer theory (DST) and Dezert-Smarandache theory (DSmT) both being unable to deal with uncertain information, the uncertainty mass in the frame was defined and two kinds of adaptive universal proportional redistribution rules (AUPR) were proposed. Next, a general evidence reasoning fusion structure was proposed based on the general evidence with which the reasoning machine was built. Lastly, the pioneer 2-DXe mobile robot was used to build the belief distribution maps of various environments. The experimental results verify the validity and the practicality of the proposed methods. They also supply powerful theoretical evidence for constructing a uniform information fusion frame.

**Keywords:** evidence reasoning; fusion frame; map building; information fusion

证据推理是信息融合的重要理论基础,但从证据理论诞生至今,尚未出现一个统一的融合框架,这与证据理论的应用特殊性有关,因为随着证据源的增加,其计算复杂度也急剧增加,这使得应用难度加大,因此为了简化计算,通常都是具体问题具体对待,没有统一的处理方法,这也使得证据理论的应用与推广难度加大.因此,研究和提出统一的证据推理框架有助于标准化证据推理,使其能够得到更为广泛应用.

## 1 证据理论简介

### 1.1 DST 和 DSmT

Dempster 在贝叶斯概率论的基础上,在 1967 年

首先提出了证据理论,他的学生 G. Shafer 随后进一步将其发展成为一种不精确推理理论,即 Dempster-Shafer 证据理论(DST)<sup>[1]</sup>.该理论以数字化的证据支持度处理证据的权重,主要致力于证据的组合.经由几十年的发展及研究,DST 证据理论的应用性得到了广泛的证实,使得该理论获得了众多学者的认可,成为一种经典的信息融合理论.

Dezert 和 Smarandache 于 2002 年提出了 DSmT (Dezert-Smarandache theory)<sup>[2]</sup>,它是在 DST 的基础上发展而来的,是 DST 和贝叶斯理论的扩展,其描述和处理融合问题的范围和能力远远强于 DST,克服了 DST 难以解决证据冲突问题的固有缺陷,具有广阔的应用前景.

### 1.2 冲突因子与不确定因子

在 DST 和 DSmT 中冲突因子<sup>[3]</sup>都被定义为

收稿日期:2010-04-21.

基金项目:国家自然科学基金资助项目(60675028).

通信作者:黄心汉. E-mail: xhhuang@mail. hust. edu. cn.

$$h_{1,2,\dots,s} = \sum_{\substack{X_1, X_2, \dots, X_s \in D^\theta \\ X_1 \cap X_2 \cap \dots \cap X_s = \emptyset}} \prod_{i=1}^s m_i(X_i).$$

但 DST 和 DSMT 都未定义并集焦元,在许多情况下并集焦元通常描述的都是不确定的信息,因此将并集焦元定义为不确定因子:

$$u_{1,2,\dots,s} = \sum_{\substack{X_1, X_2, \dots, X_s \in D^\theta \\ X_1 \cup X_2 \cup \dots \cup X_s = \emptyset}} \prod_{i=1}^s m_i(X_i).$$

### 1.3 自适应通用分配法则

信息融合的目的是消除信息的冲突与不确定,使原本不精确、不确定甚至高冲突的信息变得清晰明了.在信息融合的过程中,常常会产生冲突因子和不确定因子.冲突因子可以根据 PCR 法则<sup>[45]</sup>将其消除,但不确定因子却没有相应的消除法则.而在很多情况下,不确定因子与冲突因子一样也需要消除掉,如何处理不确定因子也是非常重要的问题.

为了使融合结果更具有确定性意义,提出了一种自适应通用分配法则 AUPR (adaptive universal proportional redistribution rule),使得信息融合过程中可以视具体情况同时将冲突因子和不确定因子分配到其他非空的确定性集合上,从而达到加强确定性命题的目的.

在 DSMT 框架下,考虑到分配精度和实时性的要求,提出了一种基于 PCR 的自适应通用分配法则,根据应用需要设定一阈值,当不确定因子大于该阈值时,说明不确定信度值太高,当前证据已无法将其消除,只能等待进一步的证据收集;当不确定因子小于阈值时,表明该因子是可消除的,则采用通用分配法则将冲突因子和不确定因子一起分配到其他焦元上.

AUPR 分为 2 种分配方式,一种是在分配冲突因子的同时一起分配不确定因子,称之为 AUPR1;另一种是在计算出合取形式后,根据合取形式的相对比例分配不确定因子,称之为 AUPR2.下面给出 2 种分配方式的表达式.

**AUPR1** 自适应通用分配法则 1 在分配全局不确定因子时只涉及到相关的冲突量而不是所有非空集合,并按照所对应的信度矩阵的非空列的比例将其分配到所有非空集合上.对于  $s \geq 2$  个证据源时,  $\forall (X \neq \emptyset) \in G^\theta$ , AUPR1 的计算公式为

$$m_{\text{AUPR1}}(X) = m_{\text{PCR}}(X) + \frac{c_{12\dots s}(X)}{f_{12\dots s}} \cdot L(X) \cdot u_{12\dots s}(X_\cup). \quad (1)$$

式中:  $m_{\text{PCR}}(X)$  是由 PCR 规则融合得出的无冲突因

子的信度赋值;  $c_{12}(X)$  是与  $X$  相关的信度赋值之和;  $c_{12\dots s}(X) = m_1(X) + m_2(X) + \dots + m_s(X) \neq 0$ ;  $u_{12}(X_\cup)$  为全局不确定因子;  $f_{12}$  是与不确定因子相关的信度赋值之和.  $L(X)$  为不确定因子阈值函数,其作用是根据当前证据自动找出阈值并判断是否分配不确定因子,表达式如下:

$$L(X) = \begin{cases} 1, & u_{12\dots s}(X) \leq \min[m_{12\dots s}(X_1), \dots, m_{12\dots s}(X_s)]; \\ 0, & u_{12\dots s}(X) \geq \max[m_{12\dots s}(X_1), \dots, m_{12\dots s}(X_s)]. \end{cases} \quad (2)$$

**AUPR2** 自适应通用分配法则 2 是按合取一致形式的比例将局部不确定因子分配到与其相关的元素上.对于  $s \geq 2$  个证据源时,  $\forall (X \neq \emptyset) \in G^\theta$ , AUPR2 的计算公式为

$$m_{\text{AUPR2}}(X) = m_{\text{PCR}}(X) + m_{12\dots s}(X) \cdot \left( \sum_{k=1}^{s-1} U^{\text{AUPR2}}(X, k) \right). \quad (3)$$

式中:  $L(X)$  与式(2)相同,  $U^{\text{AUPR2}}(X, k)$  表达式如下:

$$U^{\text{AUPR2}}(X, k) = \sum_{\substack{X_{i_1}, \dots, X_{i_k} \in G^\theta / \{X\} \\ \{i_1, \dots, i_k\} \in P \\ X_1 \cap X_2 = X}} \frac{m_{12\dots s}(X \cup X_{i_1} \cup \dots \cup X_{i_k})}{m_{12\dots s}(X) + \sum_{j=1}^k m_{12\dots s}(X_{i_j})}.$$

## 2 广义证据推理结构

### 2.1 证据推理机的基本框架

Shafer 于 1976 年提出了著名的 DS 证据理论之后,许多研究人员也相继根据 DS 理论提出了一些相应的证据理论,以解决 DS 证据理论所无法处理的高冲突问题.但迄今为止,仍然没有一个统一的融合结构.

综合过去的各类证据推理方法,大致可以将证据推理划分为 4 个层面:证据源层、信度分配层、信度融合层以及决策层.而这些理论通常都是基于等可靠信息源的,当信息源是非等可靠的且其不可靠程度是已知的,就可以将获取到的证据加以特殊处理,如 Shafer 提出的折扣理论.因此,可以将信度校正作为一个新的层次加入到证据推理的结构中去,其位置在信度分配层与信度融合层之间.证据推理机(evidence reasoning machine, ERM)的基本框架如图 1 所示<sup>[6]</sup>.信度融合层可以采用各种不同的证据理论,如 DST 或 DSMT 等.

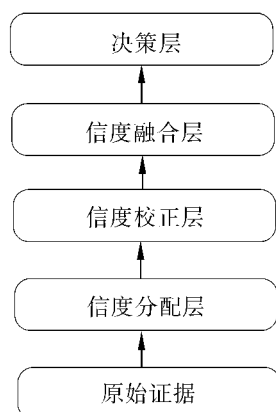


图1 证据推理机的基本框架

Fig. 1 The basic frame of evidence reasoning machine

## 2.2 基于 DS<sub>m</sub>T 的广义证据推理机

文献[6]中提出了基于 DS<sub>m</sub>T 的广义证据推理机,但其不能分配不确定因子,为此对其加以改进,使其更具普适性. 基于 DS<sub>m</sub>T 的二元素改进广义证

据推理机 (general evidence reasoning machine, GERM) 如图 2 所示.

在信度分配层,  $F(S)$  为信度赋值函数, 通过信度分配函数之后便成为了原始的基本信度赋值  $O(\cdot)$ . 对于 2 焦元的辨识框架, 通过交运算和并运算获取的基本信度赋值只有 4 种. 在信度校正层中, 没有采用 Shafer 的折扣方法, 取而代之的是人工神经网络方法. 因为在大多数情况下, 非等可靠证据源的折扣信息是无法得知的, 即使能够获取其折扣值, 但由于各种条件所限, 往往也会呈现出非线性状态, 而折扣方法却是线性的, 而且一旦确定就无法改变, 这使得其应用价值大大降低. 而神经网络方法则更为灵活通用, 它可以根据先验知识拟合非线性的折扣值, 因此可以适应不同的条件, 比 Shafer 的折扣方法更为精确地描述非线性的打折情况.  $m(\cdot)$  即为通过神经网络校正之后的基本信度赋值.

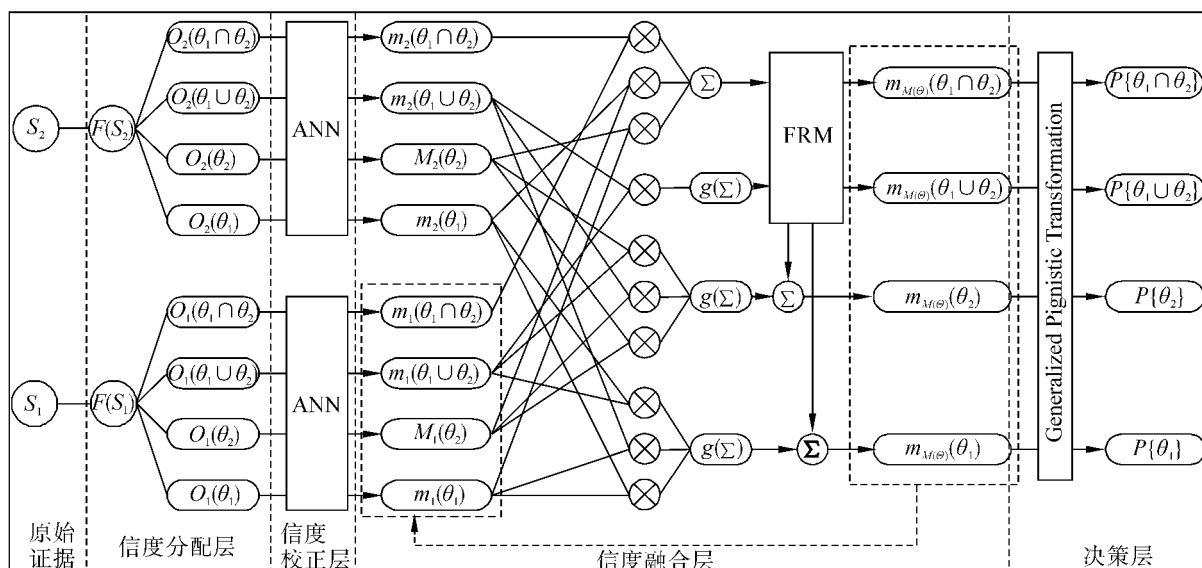
图2 基于 DS<sub>m</sub>T 的广义证据推理机Fig. 2 DS<sub>m</sub>T based generalized evidence reasoning machine

图 2 中 FRM (factor redistribution machine) 是因子分配器信度校正层  $\otimes$  是乘法算子,  $g(\Sigma)$  是激励函数, 对于 DS<sub>m</sub>T 而言, 激励函数就是比较简单的求和算子, 也可以采用其他证据理论的算法如 DST (若采用 DST, 则激励函数就相对 DS<sub>m</sub>T 复杂一些, 包含了除法运算).  $m_{M(\theta)}(\cdot)$  融合后的结果. FRM 是因子分配器, 冲突因子和不确定因子通过分配器被重新分配到  $m_{M(\theta)}(\theta_1)$  和  $m_{M(\theta)}(\theta_2)$  上, 如果冲突因子或不确定因子不需分配, 则可直接通过分配器成为  $m_{M(\theta)}(\theta_1 \cap \theta_2)$  和  $m_{M(\theta)}(\theta_1 \cup \theta_2)$ . 分配器中的算法可以采用自适应通用分配法则 (AUPR), 也可采用其他方法, 如只需分配冲突因子时, 就可只采用 PCR 法则.

最后的决策层是一个扩展层, 采用广义 Pignis-

tic 转换来计算元素的发生概率, 但通常情况下不需要这个扩展层.

对于整个推理机而言, 只有 2 个证据源输入口, 但其能够处理任意  $N \geq 2$  个证据源的情况. 假定有一组含有  $n$  个证据源的有限集  $\{X_1, X_2, \dots, X_n\}$ , 现将这个有限集依次送入推理机, 即  $X_1$  和  $X_2$  作为初始的  $S_1$  和  $S_2$ , 在第 1 轮融合周期结束后, 由  $X_1$  和  $X_2$  2 个证据源融合得到结果  $m_{M(\theta)}^1(\cdot)$  不是最终的结果, 而是一个中间结果, 因此  $m_{M(\theta)}^1(\cdot)$  又重新变为  $m(\cdot)$ , 与新进入推理机的证据源  $X_3$  进行融合, 此时  $X_3$  与上一轮结果  $m_{M(\theta)}^1(\cdot)$  分别成为了新一轮融合的  $S_1$  和  $S_2$ , 只不过  $m_{M(\theta)}^1(\cdot)$  是直接进入信度融合层而无需再通过信度分配和信度校正层 ( $X_3$

需通过这2层).  $X_3$  与  $m_{M(\theta)}^1(\cdot)$  通过第2轮融合后又可获得一个新的中间融合结果  $m_{M(\theta)}^2(\cdot)$ , 接下来  $m_{M(\theta)}^2(\cdot)$  与  $X_4$  又进入第3轮融合周期. 如此循环, 直至所有的原始证据源都进入推理机. 当最后一个证据源  $X_n$  进入推理机并获得了融合结果  $m_{M(\theta)}^n(\cdot)$ , 倘若没有更新的证据送入推理机, 则  $m_{M(\theta)}^n(\cdot)$  便是最终融合结果了. 当获取到最终结果后, 如果需要则可让其进入到决策层.

在2个元素  $\theta_1$  和  $\theta_2$  的情况下, 广义证据推理机包含了经典 DSsm 模型和混合 DSsm 模型, 约束条件的附加是在信度分配层进行的, 即  $F(S)$  函数. 无约束条件则为经典 DSsm 模型, 若  $F(S)$  中有附加的约束项, 则变为了混合 DSsm 模型. 若元素个数大于2, 则信度分配层和信度融合层就变得更为复杂, 其复杂度增长速度非常惊人, 不过大多数情况下2个元素已经足够, 因为任何问题都可以分解为“是”或“否”这个元素.

这个广义证据推理机同样也适用于 DST 理论框架下的各种证据理论. 在信度分配层, 信度赋值函数将冲突分量的系数置为0, 则整个推理机就工作在 Shafer 模型下了. 之后信度融合层的激励函数  $g(\Sigma)$  也需修改为 DST 的融合法则. 对于其他的证据理论而言情况也相差无几, 只需修改信度赋值函数和激励函数的融合算法就可以了.

广义推理机不仅适用于定量信息融合, 同样也适用于定性信息融合以及混合信息融合, 只需采用相应的融合算法即可.

### 3 实验结果及分析

实验采用 Pioneer 2-DXe 移动机器人, 机器人本体上装有16个声呐, 对声呐的建模见文献[7]. 建立  $4\,840\text{ mm} \times 3\,100\text{ mm}$  的房间地图, 实验环境和机器人初始位置如图3所示, 进行构建环境地图实验. 设定机器人的初始位置为地图的坐标原点, 初始位姿为  $(0, 0, 0)$ .

采用提出的 GREM 作为融合框架, 在 GREM 中有信度校正层. 由于每个声呐都是一个独立的证据源, 因此必须对每个声呐都进行信度校正, 而校正所用的折扣值则由神经网络训练得到. 出于对速度和复杂度的需求, 采用了最为简单但很有效的3层 BP 网络, 训练函数采用较快的 LM (levenberg-marquardt) 算法, 激励函数采用 Sigmoid 函数. 功能函数采用 SSE (sum squared error). 学习速率设定为0.1, 最终误差设定为0.001. 为了使计算更为精确, 将输入输出值都放大1 000倍. 每个声呐都需要训练一个 BP 网络, 因此一共需要训练16个网络.

GREM 的信度融合层的算法可以采用贝叶斯概率法、DST 或 DSsmT 等. 考虑到 DSsmT 算法的优越性, 采用其作为 GREM 的融合算法. 由于融合过程中会产生冲突因子和不确定因子, 因此需采用 AUPR 方法来分配因子. 虽然不确定因子对地图精确性的影响不如冲突因子大, 但微小的不确定因子是完全可以消除的, 因此也可以采用基于 PCR2 的 AUPR1 法则 (AUPR1 计算复杂度要小于 AUPR2), 即 PCR2-AUPR1 算法.




图3 实验环境及机器人初始位置

Fig. 3 Experiment environment and original position of robot

分别进行2组探测未知环境的实验, 第1组采用经典 DST 的方法, 第2组采用 PCR2-AUPR1 方法.

实验结果如图4和图5所示. 图4为2种算法得到的不确定区域, 灰度值越大表示不确定的信度值越大, 即表明该区域的信息不足不明, 无法得知. 图5为2种算法计算出的最终信度分布图, 灰度值越大表示该区域被占用的可能性越大.




(a) DST 算法得到的不确定区域




(b) PCR2-AUPR1 算法得到取的不确定区域

图4 不确定区域比较

Fig. 4 The comparison of uncertainty area



(a) DST 算法实验结果



(b) PCR2-AUPR1 算法实验结果

图5 最终实验结果比较

Fig.5 The comparison of final experiment results

由实验结果可以看出,DST 存在固有的融合缺陷,它无法处理高冲突信息,在处理高冲突信息时往往得出反人类直觉的结果,占地面积小的障碍物往往会被该区域所覆盖而被标记为空,其描绘出的最终地图实际上是整个场景的外部轮廓,而且 DST 所计算出的不确定信度分布图也与实际场景不符,已被机器人探测过的部分仍然有不确定因子存在(即图 4(a)中散布的黑斑),而且信度值都很低,表明了融合的不完善;实际上被探测过的部分已经获取到了充分证据,这些不确定因子完全可以消除掉。

与 DST 相比,PCR2-AUPR1 方法能很好地分配冲突因子和不确定因子,消除了信度值很低的不确定因子,使得不确定因子信度分布图的解释更加合理,因此所绘制的最终地图则更为接近真实环境。


#### 4 结束语

本文在 DSmT 框架下定义了不确定因子,提出了 2 种自适应通用分配法则,使得证据推理过程中产生的低信度不确定焦元得到了合理的分配和解释。同时提出了基于证据理论的统一融合框架,构造了广义证据推理机。最后以移动机器人为实验平台进行了 2 组实验,分别构造了未知环境的不确定因子信度分布图和最终信度分布图。实验结果表明本文提出的 AUPR 方法和广义证据推理机能有效地处理高冲突和不确定信息,能更精确合理地反映真实环境地图,是一种先进的证据推理融合结构。

#### 参考文献:

- [1] SHAFER G. A mathematical theory of evidence[M]. Princeton, USA: Princeton University Press, 1976: 1-100.
- [2] DEZERT J. Foundations for a new theory of plausible and paradoxical reasoning[J]. Information and Security, 2002, 9: 13-57.
- [3] SMARANDACHE F, DEZERT J. Advances and applications of DSmT for information fusion[M]. Rehoboth, USA: American Research Press, 2004: 3-31.
- [4] SMARANDACHE F, DEZERT J. Advances and applications of DSmT for information fusion[M]. Rehoboth, USA: American Research Press, 2006: 47-49.
- [5] SMARANDACHE F, DEZERT J. Advances and applications of DSmT for information fusion[M]. Rehoboth, USA: American Research Press, 2009: 137-160.
- [6] HUANG Xinhan, LI Peng, WANG Min. Evidence reasoning machine based on DSmT for mobile robot mapping in unknown dynamic environment[C]//2009 IEEE International Conference on Robotics and Biomimetics. Guilin, China: 2009: 753-758.
- [7] 李鹏, 黄心汉, 王敏. 基于混合 DSm 模型的移动机器人动态环境地图构建[J]. 机器人, 2009, 31(1): 40-46, 52.  
LI Peng, HUANG Xinhan, WANG Min. Hybrid-DSm-model-based mobile robot map building in dynamic environment [J]. Robotics, 2009, 31(1): 40-46, 52.

#### 作者简介:



黄心汉,男,1946 年生,教授,博士生导师。主要研究方向为智能控制、智能机器人、多传感器集成与信息融合等。曾任国家“863”计划智能机器人主题控制专题专家组成员。现任中国人工智能学会常务理事、智能机器人专业委员会主任等职。发表学术论文 300 余篇。



李鹏,男,1981 年生,博士研究生。主要研究方向为信息融合、机器人地图创建与定位、多机器人系统。发表学术论文 10 余篇。



王敏,女,1954 年生,教授。主要研究方向为图像处理与模式识别技术、机器人视觉与传感技术、智能控制与神经元网络原理及应用等。现任中国人工智能学会理事、智能机器人专业委员会秘书长等职。发表学术论文 80 余篇,出版教材 3 部。