

## 基于团树传播的证据网络推理算法

吴根秀, 黄涛<sup>†</sup>, 赖岳, 杨莎莎

(江西师范大学 数学与信息科学学院, 南昌 330022)

**摘要:** 将团树传播算法应用于证据网络中, 解决复杂的多连通知识网络结构下的信度推理问题. 将复杂多连通网络构造成一棵团树, 并将联合信度作为团节点的参数实现复杂多连通网络结构上的证据网络信度推理. 在进行联合信度函数信息融合的过程中, 通过引入两种新的交并运算实现对DSmT组合规则的改进, 减少不确定性. 最后通过实例验证了所提出方法的可行性.

**关键词:** 团树传播算法; 证据网络; 信度推理; 信息融合

中图分类号: TP18

文献标志码: A

## Reliability inference method for evidential network based on the clique tree propagation algorithm

WU Gen-xiu, HUANG Tao<sup>†</sup>, LAI Yue, YANG Sha-sha

(School of Mathematics and Information Science, Jiangxi Normal University, Nanchang 330022, China)

**Abstract:** For solving the reliability inference problem in the multi-connected knowledge network model, a clique tree propagation algorithm is innovatively applied to the evidential network. Firstly, the multi-connected knowledge network model is clustered as a clique tree, and the joint belief function is regarded as the main parameter of the cluster nodes, therefore, the information each node is obtained, which facilitates the possibility of reliability inference within the multi-connected knowledge network model. In the process of evident fusion of the joint belief function, two new union and intersection methods are introduced to improve the existing DSmT theory, which helps to eliminate the influence of conflicting evident information on other evident variables. Finally, an example is given to illustrate the feasibility of the proposed method.

**Keywords:** clique tree propagation algorithm; evidential network; reliability inference; information fusion

### 0 引言

证据网络(EN)是一种D-S证据理论与图模型相结合的有向无环图模型<sup>[1-5]</sup>,由变量节点、连接变量节点的有向边和节点间的关系3部分组成.在满意度评估、目标威胁评估、智能控制和诊断推理等方面得到了大量应用.信度网络又称为贝叶斯网络,于1988年由Pearl第一次提出,是在多元统计分析技术中基于概率推理的数学模型.已有的信度网络推理算法<sup>[6-7]</sup>可分为两种,即近似推理算法和精确推理算法.其中团树传播算法<sup>[8-9]</sup>是一种应用范围最广、计算速度最快的精确推理算法,适用于单连通和复杂多连通网络模型.

目前,实现证据网络推理的方法主要包括条件信

任证据网络推理、联合信任证据网络推理和信度规则证据网络推理<sup>[10-12]</sup>.Shenoy<sup>[13]</sup>提出一种结合多种不确定知识表示方法的价值网络理论框架,该方法在不同的识别框架下,通过扩展和边际化两种方法实现信息的传递和组合,并取得了理想的效果,但对于复杂的网络模型,该方法运算复杂度高,需要的存储空间大,降低了推理效率.Boutheina等<sup>[14]</sup>提出了基于二进制树的证据网络推理方法,该方法不能避免多连通网络结构的消息往复问题.郭强等<sup>[15]</sup>提出一种基于混合参数和DSmT的证据网络多连通结构推理方法,该方法只能推理出一个变量的信任值.对于复杂的多连通的证据网络知识结构,现有的推理方法很匮乏,但在现实网络结构中复杂多连通的结构很多,寻

收稿日期: 2015-12-30; 修回日期: 2016-05-05.

基金项目: 江西省自然科学基金项目(20151BAB207030); 江西省教育厅科技项目(GJJ14244).

作者简介: 吴根秀(1965—),女,教授,从事信息融合、不确定性推理等研究; 黄涛(1991—),女,硕士生,从事信息融合、不确定性推理的研究.

<sup>†</sup>通讯作者. E-mail: 757184827@qq.com

找出解决这类问题的方法是很有意义的。

针对以上问题,通过结合证据网络和信度网络推理算法研究发现,借鉴价值网络的思想,将团树传播的推理方法应用在证据网络中,可以在复杂多连通网络中避免消息往复传播的问题上,使得推理可以有效进行. 本文将基于团树传播算法的方法应用在多连通证据网络模型中,解决了多连通证据网络模型下消息往复传播问题,可以得到任意一个网络结构中节点变量的信息. 通过定义两种新的交并运算,改进了在多维识别框架下混合DSmT组合规则<sup>[16]</sup>,提高了信息融合的确定性. 最后以胸腔医学诊断问题为实例,验证了所提出方法是一种行之有效的推理方法.

### 1 基础理论

#### 1.1 多维识别框架下的信度函数理论

记  $N = \{1, 2, \dots, n\}$ ,  $\{X_i\}_{i \in N}$  是一组随机变量, 每一个变量  $X_i$  取有限集, 称  $X_N = X_1 \times X_2 \times \dots \times X_n$  为多维识别框架. 若  $K \subseteq N$ , 则称  $X_K = \prod_{i \in K} X_i$  为  $X_N$  的子框架; 若  $K \subseteq N, L \subseteq N$ , 则称  $X_K \times X_L = \prod_{i \in L \cup K} X_i$  为  $X_K$  和  $X_L$  上的联合空间.  $x = (x_1, x_2, \dots, x_n) \in X_N$  到  $X_K$  的投影记为  $x^{\downarrow K}$ , 即给定  $K = \{i_1, i_2, \dots, i_k\}$ , 有  $x^{\downarrow K} = (x_{i_1}, x_{i_2}, \dots, x_{i_k}) \in X_K$ . 类似地, 给定  $M \subseteq K \subset L \subseteq N$  和  $A \subseteq X_K$ ,  $A^{\downarrow M}$  表示  $A$  到  $X_M$  的投影,  $A^{\downarrow M} = \{y \in X_M | \exists x \in A : y = x^{\downarrow M}\}$ ;  $A^{\uparrow L}$  表示  $A$  到  $X_L$  的扩张,  $A^{\uparrow L} = \{y \in X_L | \exists x \in A : y^{\downarrow K} = x\}$ .

**定义1** 已知多维识别框架  $X_N$ , 如果函数  $m : P(X_N) \rightarrow [0, 1]$ , 满足  $\sum_{A \subseteq X_N} m(A) = 1, m(\emptyset) = 0$ , 则称  $m$  为  $X_N$  上的基本信度分配函数.

对于任意  $A \subseteq X_N$ , 称  $Bel(A) = \sum_{B \subseteq A} m(B)$  为信函数; 称  $Pl(A) = \sum_{B \cap A \neq \emptyset} m(B)$  为似真度函数.

**定义2** 设  $M \subset K \subseteq N, m$  为  $X_K$  上的基本信度分配, 称

$$m^{\downarrow M}(A) = \sum_{B \in X_K, B^{\downarrow M} = A} m(B), \forall A \subseteq X_M \quad (1)$$

为  $m$  在  $X_M$  上的边际化.

**定义3** 设  $K \subset L \subseteq N, m$  为  $X_K$  上的基本信度分配, 称

$$m^{\uparrow L}(A) = \sum_{B \in X_K, B^{\uparrow L} = A} m(B), \forall A \subseteq X_L \quad (2)$$

为  $m$  在  $X_L$  上的扩张.

**定义4** 设同一个多维识别框架  $X_N$  上两个独立证据, 其相应的基本信任分配为  $m_1$  和  $m_2$ , 则用

Dempster 组合规则组合后的证据  $m = m_1 \oplus m_2$  由下式计算可得:

$$m(C) = \frac{1}{1-K} \sum_{A, B \in X_N, A \cap B = C} m_1(A)m_2(B) (C \neq \emptyset), \quad (3)$$

其中  $K = \sum_{A, B \in X_N, A \cap B = \emptyset} m_1(A)m_2(B)$ . 当  $C = \emptyset$  时  $m(C) = 0$ .

**定义5** 设  $m_{X_L}$  和  $m_{X_K}$  是分别定义在多维识别框架  $X_L$  和  $X_K$  上的基本信任分配函数, 不同空间的合成规则定义为

$$m_{X_L} \oplus m_{X_K} = m_{X_L}^{\uparrow X_L \times X_K} \oplus m_{X_K}^{\uparrow X_L \times X_K}. \quad (4)$$

**定义6** 设  $K, L \subset N$  且  $K$  与  $L$  互不相交,  $m$  为  $X_{K \cup L}$  上的基本信度分配, 给定  $A \subseteq X_K$ , 对于  $\forall B \subseteq X_L$ , 称

$$m_{X_L|X_K=A}(B|A) = \sum_{C \subseteq X_{K \cup L}, (C \cap A)^{\uparrow K \cup L} = B} m(C) \quad (5)$$

为  $m$  在给定  $A$  的条件下  $X_L$  上的条件基本信任分配. 记  $m_{X_L|X_K}$  为  $m$  在给定条件  $X_K$  下  $X_L$  上的条件基本信任分配.

在证据理论中, 条件证据函数之间可以相互转化, 即对于  $K, L \subset N$  且  $K$  与  $L$  互不相交, 有如下关系 (以下将  $X_L|X_K$  简记为  $L|K$ ):

$$Bel_{L|K=A}(B|A) = \sum_{C \subseteq X_L, C \subseteq B} m_{L|K=A}(C|A), \quad (6)$$

$$Pl_{L|K=A}(B|A) = \sum_{C \subseteq X_L, C \cap B \neq \emptyset} m_{L|K=A}(C|A), \quad (7)$$

$$Bel_{L|K=A}(B|A) = 1 - Pl_{L|K=A}(\bar{B}|A), \quad (8)$$

$$m_{L|K=A}(B|A) = \sum_{C \subseteq B} (-1)^{|B-A|} Bel_{L|K=A}(C|A), \quad (9)$$

$$Pl_{K|L=B}(A|B) = 1 - \prod_{x_i \in A} (1 - Pl_{L|K=A}(B|x_i)). \quad (10)$$

#### 1.2 证据网络的推理

证据网络主要由网络结构和网络参数两部分组成, 表示为  $EN = \{(H, M), B\}$ . 其中:  $H, M$  分别为网络结构中节点的集合和连接节点有向边的集合, 即  $\{H, M\}$  为含有  $|H|$  个节点的有向无环图;  $B$  为节点间的信度函数关系集合, 其编码了一组变量之间的相互关系 (网络参数). 一个基本的证据网络如图1所示.

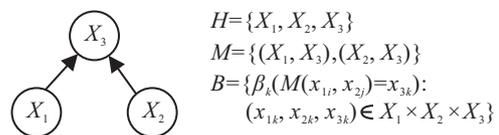


图1 基本的证据网络模型

1.2.1 正向推理

如图1所示的证据网络模型,假设节点 $X_1$ 和 $X_3$ 的识别框架为 $X_1$ 和 $X_3$ ,已知框架 $X_1$ 的基本信任分配为 $m_{X_1}$ ,条件基本信任分配为 $m_{X_3|X_1}$ ,由正向推理<sup>[11]</sup>,给定 $A \subseteq X_1$ ,对于 $\forall B \subseteq X_3$ ,有

$$m_{X_3}(B) = \sum_{A \subseteq X_1} m_{X_1}(A)m_{X_3|X_1=A}(B|A). \quad (11)$$

1.2.2 反向推理

已知识别框架 $X_3$ 上的基本信任分配和条件基本信任分配为 $m_{X_3}$ 和 $m_{X_3|X_1}$ ,首先由式(7)将 $m_{X_3|X_1}$ 转化为 $Pl_{X_3|X_1}$ ,然后通过式(10)转化为 $Pl_{X_1|X_3}$ ,接着由式(8)将 $Pl_{X_1|X_3}$ 转化为 $Bel_{X_1|X_3}$ ,最后由式(9)转化为 $m_{X_1|X_3}$ ,可得

$$m_{X_1}(B) = \sum_{A \subseteq X_3} m_{X_3}(A)m_{X_1|X_3}(B|A). \quad (12)$$

1.3 团树传播算法

团树构造常见方法主要有标准方法、图消元方法和变量消元方法<sup>[8]</sup>. 本文选用标准方法将一个信度网构造成一棵团树,推理过程中先将定义在团树上的信息(如概率、条件概率)转化为信度(条件信度),或者直接给出团节点的信度值. 在团节点之间进行信度计算,以完成对整个网络的推理计算. 下面以胸腔医学诊断问题的证据网络多连通结构<sup>[11]</sup>为例来说明团树的构造及其推理过程.

1) 团树的构造.

应用标准方法得到团树如图2所示,并将每个节点上的信息转化为信度.

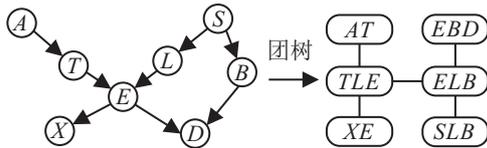


图2 由贝叶斯网转化为团树

2) 团树传播算法过程.

团树传播算法的主要思想是在给定的网络模型下,根据已知的节点信度和其与未知节点间的条件信度计算出所感兴趣节点的信度,团节点用联合信度的形式表达,团节点与团节点之间的信息传递通过条件信度连接. 具体推理过程如图3所示.



图3 团树传播算法流程

2 基于团树传播算法的证据网络推理模型

2.1 以联合信度作为团节点间参数的团树传播推理算法

在多连通证据网络模型下,由于节点间会形成闭合的圈,即节点间形成两条及以上的通道,那么用单

连通的方法便会出现消息往复传播问题. 基于该问题,本文结合团树传播算法的特点,将团树传播算法对后验概率的计算转化为证据函数的计算,用证据函数作为参数进行推理计算. 算法步骤如下.

Step 1: 团树初始化. 对于贝叶斯网中的每个节点,在团树中找到一个家族覆盖团,将已知的信度储存在该团处,若分配过程结束时有一个团没有储存任何的信度,则将单位1存在该团处.

Step 2: 设置证据变量 $E = e$ ,将含有 $E = e$ 的因子中 $E$ 的信度取 $e$ 的信度.

Step 3: 选择一个包含查询变量的团 $C_Q$ 作为推理枢纽.

Step 4: 信息收集阶段. 计算团 $C_Q$ 的相邻节点 $C_{nb}$ 到 $C_Q$ 的信息传递 $M_{C_{nb} \rightarrow C_Q} = V_{C_{nb}} \downarrow^{C_{nb} \cap C_Q}$ ,其中 $V_{C_{nb}}$ 是团节点 $C_{nb}$ 处储存的各个随机变量的联合信度函数, $C_{nb}$ 不是叶子结点,要一步一步从叶子结点收集.

Step 5: 提取答案. 对于每个非证据变量 $X$ ,首先需要找到一个包含它的团 $C_X$ ,然后将 $C_X$ 收集的信息和储存在 $C_X$ 处信度进行合成,得到 $C_X$ 上的联合信度,即 $m_{C_X} = V_{C_X} \oplus (M_{i \rightarrow C_X} | i \in N_{C_X})$ . 将 $m(C_X)$ 中消除 $X$ 以外的变量,进行边际化即可得到所感兴趣的信度值.

例如,在图2所示的团树中,先对团树初始化,得到每一个团的联合信度函数 $V_i (i = 1, 2, \dots, 6)$ (见图4). 选择团 $[TLE]$ 作为推理枢纽,为了推理书写简便,记各个团为 $h_1 = \{T, L, E\}, h_2 = \{A, T\}, h_3 = \{X, E\}, h_4 = \{E, B, D\}, h_5 = \{S, L, B\}, h_6 = \{E, L, B\}$ . 进行信息收集,信息传递情况如图4实线箭头所示,从叶子节点开始收集信息,即

$$M_{2 \rightarrow 1}(T) = V_2 \downarrow^{h_1 \cap h_2}, \quad (13)$$

$$M_{3 \rightarrow 1}(E) = V_3 \downarrow^{h_1 \cap h_3}, \quad (14)$$

$$M_{4 \rightarrow 6}(E, B) = V_4 \downarrow^{h_4 \cap h_6}, \quad (15)$$

$$M_{5 \rightarrow 6}(L, B) = V_5 \downarrow^{h_5 \cap h_6}, \quad (16)$$

$$M_{6 \rightarrow 1}(L, E) = (V_6 \oplus M_{4 \rightarrow 6} \oplus M_{5 \rightarrow 6}) \downarrow^{h_1 \cap h_2}. \quad (17)$$

提取答案

$$m_{C_X} = V_{C_X} \oplus (M_{i \rightarrow C_X} | i \in N_{C_X}). \quad (18)$$

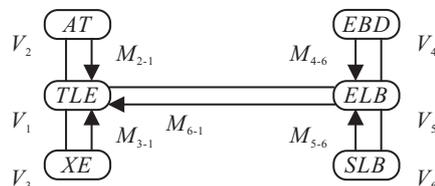


图4 团树传播算法示例,这里 $[TLE]$ 是枢纽节点

在图4中,团节点[*TLE*]处的联合信度的基本信任分配为

$$m(T, L, E) = V_1 \oplus (M_{2 \rightarrow 1}(T) \oplus M_{3 \rightarrow 1}(E) \oplus M_{6 \rightarrow 1}(L, E)). \quad (19)$$

感兴趣变量*T*的基本信任分配值为

$$m(T) = [V_1 \oplus (M_{2 \rightarrow 1}(T) \oplus M_{6 \rightarrow 1}(L, E))] \uparrow^T. \quad (20)$$

**2.2 混合DSmT组合规则的改进**

利用定义4的D-S组合规则对联合信任函数进行融合时会出现高冲突情况,冲突的程度越大,融合的结果越差.为了解决该问题,首先考虑应用混合DSmT组合规则<sup>[16]</sup>降低冲突的程度.但约束条件μ的加入使得冲突的一个变量会影响其他不冲突变量的融合,使确定的信息传递到未知集中,将融合得到的信息进行边际化操作时使得未知集中的信度增大,在实际的问题中会增大不确定性.本文通过定义两种新的交并运算改进融合规则,以解决以上问题.

下面通过一个例子说明具体过程.团节点[*BLE*]接收相邻节点传来的信息为

$$m_1(B = Y, L = N, E = \theta) = 0.9, \\ m_1(B = N, L = \theta, E = Y) = 0.1.$$

加入约束条件μ(θ = N ∪ Y, Y ∩ N = ∅).该节点本身存储的证据网络联合信度函数参数为

$$m_2(B = N, L = \theta, E = Y) = 0.1, \\ m_2(B = N, L = N, E = N) = 0.9.$$

D-S融合规则见表1.由表1可见,融合后的信度0.99都分配到了冲突项中,为降低冲突程度,应用混合DSmT组合规则进行融合,见表2.

**表1 D-S组合规则**

	$m_2(N, \theta, Y)$	$m_2(N, N, N)$
	0.1	0.9
$m_1(Y, N, \theta)$	$m_{12}(\theta, \theta, \theta)$	$m_{12}(\theta, \theta, \theta)$
0.9	0.09	0.81
$m_1(N, \theta, Y)$	$m_{12}(N, \theta, Y)$	$m_{12}(\theta, \theta, \theta)$
0.1	0.01	0.09

**表2 通过混合DSmT规则融合**

	$m_2(N, \theta, Y)$	$m_2(N, N, N)$
	0.1	0.9
$m_1(Y, N, \theta)$	$m_{12}(\theta, \theta, \theta)$	$m_{12}(\theta, N, \theta)$
0.9	0.09	0.81
$m_1(N, \theta, Y)$	$m_{12}(N, \theta, Y)$	$m_{12}(N, \theta, \theta)$
0.1	0.01	0.09

由联合基本信度函数 $m_1(Y, N, \theta)$ 和 $m_2(N, \theta, Y)$ ,进行混合DSmT融合,得到结果 $m_{12}(\theta, \theta, \theta)$ ,这是由于当变量*B*融合时, $Y \cap N = \emptyset$ ,根据混合DSmT组合规则, $[BLE] \cap [BLE]$ 变成 $[BLE] \cup [BLE]$ 取的值.基于该问题,本文通过引入两种新的交并运算改进基于联合空间下的混合DSmT组合规则.

**定义7** 设识别框架 $X_K = (X_{i1}, \dots, X_{ik}), X_N = (X_{i1}, \dots, X_{in})$ ,当 $K \subseteq N$ 时,有 $A \cap B = (A^{\downarrow X_{i1}} \cap B^{\downarrow X_{i1}}, \dots, A^{\downarrow X_{ik}} \cap B^{\downarrow X_{ik}})$ .若存在 $1 \leq j \leq k, j$ 为正整数,则 $A^{\downarrow X_{ij}} \cap B^{\downarrow X_{ij}} = \emptyset$ ,记为 $A \cap B = \emptyset$ ;否则,对于任意的*j*,有 $A^{\downarrow X_{ij}} \cap B^{\downarrow X_{ij}} \neq \emptyset$ ,记为 $A \cap B \neq \emptyset$ .

若 $A \cap B = \emptyset$ ,不妨设当 $m \leq j \leq k$ 时,有 $A^{\downarrow X_{ij}} \cap B^{\downarrow X_{ij}} = \emptyset$ ,当 $1 \leq j \leq m$ 时,有 $A^{\downarrow X_{ij}} \cap B^{\downarrow X_{ij}} \neq \emptyset$ ,则此时记

$$A \cup B = (A^{\downarrow X_{i1}} \cup B^{\downarrow X_{i1}}, \dots, A^{\downarrow X_{im}} \cup B^{\downarrow X_{im}}, \\ A^{\downarrow X_{im+1}} \cap B^{\downarrow X_{im+1}}, \dots, A^{\downarrow X_{ik}} \cap B^{\downarrow X_{ik}}).$$

**定义8** 设在同一个多维识别框架 $X_N$ 上,给定关于混合DSmT模型的两个独立证据源 $m_1$ 和 $m_2$ 分别为 $X_1 \times X_2 \times \dots \times X_n$ 空间上联合基本信任函数,在超幂集上对它们进行组合,有

$$m_1 \oplus m_2(C) = \sum_{A, B \in D^{X_N}, A \cap B \neq \emptyset, A \cap B = C} m_1(A)m_2(B) + \sum_{A, B \in D^{X_N}, A \cap B = \emptyset, A \cup B = C} m_1(A)m_2(B). \quad (21)$$

利用改进的混合DSmT规则进行该节点的信度合成,见表3.

**表3 通过改进的混合DSmT规则融合**

	$m_2(N, \theta, Y)$	$m_2(N, N, N)$
	0.1	0.9
$m_1(Y, N, \theta)$	$m_{12}(\theta, N, Y)$	$m_{12}(\theta, N, N)$
0.9	0.09	0.81
$m_1(N, \theta, Y)$	$m_{12}(N, \theta, Y)$	$m_{12}(N, N, \theta)$
0.1	0.01	0.09

将表2和表3合成后的联合基本信任函数通过式(1)进行边际化操作,得到每个变量的基本信任值,见表4.边际化操作后第1个变量*B*的信度在改进前后一致,但变量*L*、*E*改进前在未知集θ上的信度都大于改进后,改进后的信度都分配到确定集上.由表4可知,改进的规则减少了融合结果的不确定性.

**表4 改进前后边际化操作结果**

	混合DSmT融合规则			改进的融合规则		
	<i>B</i>	<i>L</i>	<i>E</i>	<i>B</i>	<i>L</i>	<i>E</i>
$m_{12}(Y)$	0	0	0.01	0	0	0.1
$m_{12}(N)$	0.1	0.81	0	0.1	0.99	0.81
$m_{12}(\theta)$	0.9	0.19	0.99	0.9	0.01	0.09

**3 实例分析**

**3.1 实例**

一个患有呼吸短促症状的病人,医生必定判断该病人由下面3种病引起:支气管炎、肺结核和肺癌.该

医生的知识网络如图2所示,  $A$ 表示近期对亚洲的访问,  $S$ 表示抽烟,  $T$ 表示肺结核,  $L$ 表示肺癌,  $B$ 表示支气管炎,  $E$ 表示肺结核或肺癌,  $X$ 表示X光检查,  $D$ 表示呼吸短促, 箭头表示前面的情况可能会导致后面症状的发生, 如  $A \rightarrow T$ 表示近期对亚洲(A)的访问有可能会增加肺结核(T)的几率. 通过先验知识得到各节点参数如表5所示.

表5 已知各变量间的基本信任分配

信度参数	基本信任分配	
$D EB$	$m(\text{是} \text{是}, \text{是}) = 0.9$	$m(\text{是} \text{是}, \text{否}) = 0.7$
	$m(\text{是} \text{否}, \text{是}) = 0.7$	$m(\text{是} \text{否}, \text{否}) = 0.7$
	$m(\text{否} \text{是}, \text{是}) = 0.1$	$m(\text{否} \text{是}, \text{否}) = 0.3$
	$m(\text{否} \text{否}, \text{是}) = 0.3$	$m(\text{否} \text{否}, \text{否}) = 0.3$
$LB S$	$m(\text{是} \text{是}, \text{是}) = 0.3$	$m(\text{是} \text{是}, \text{否}) = 0.1$
	$m(\text{是} \text{否}, \text{是}) = 0.4$	$m(\text{是} \text{否}, \text{否}) = 0.1$
	$m(\text{否} \text{是}, \text{是}) = 0.2$	$m(\text{否} \text{是}, \text{否}) = 0.1$
	$m(\text{否} \text{否}, \text{是}) = 0.1$	$m(\text{否} \text{否}, \text{否}) = 0.7$
$X E$	$m(\text{是} \text{是}) = 0.9$	$m(\text{否} \text{是}) = 0.1$
	$m(\text{是} \text{否}) = 0.1$	$m(\text{否} \text{否}) = 0.9$
$T A$	$m(\text{是} \text{是}) = 0.7$	$m(\text{否} \text{是}) = 0.3$
	$m(\text{是} \text{否}) = 0.2$	$m(\text{否} \text{否}) = 0.8$
$TLE$	$m(\text{是}, \text{否}, \text{是}) = 0.3$	$m(\text{否}, \text{是}, \text{是}) = 0.4$
	$m(\text{否}, \text{是}, \text{否}) = 0.1$	$m(\text{是}, \text{否}, \text{否}) = 0.2$

设患者呼气短促现象明显, 即  $m(D = \text{是}) = 1$ ; 近期未去过亚洲, 即  $m(A = \text{是}) = 0, m(A = \text{否}) = 1$ ; 医生初步判断患者可能是支气管炎, 即  $m(B = \text{是}) = 0.8, m(B = \text{否}) = 0.2$ ; 经过X光照射患者患有肺结核或者肺癌, 即  $m(E = \text{是}) = 1, m(E = \text{否}) = 0$ . 患者抽烟的可能信度  $m(S = \text{否}) = 1$  为证据变量, 推理结构如图3所示, 选取  $[TLE]$  作为推理枢纽点, 推理步骤如下 (选取其他团的算法结论一致).

信息收集阶段.

Step 1: 团节点  $[AT]$  储存的信度为  $m(A = \text{是}) = 0, m(A = \text{否}) = 1$ , 由  $T|A$  条件信度参数可知,  $A \rightarrow T$  为正向推理, 由式(11)可得团节点  $[AT]$  联合信度  $V_2$  的取值, 再由式(13)可得

$$M_{2 \rightarrow 1}(T = \text{是}) = 0.8, M_{2 \rightarrow 1}(T = \text{否}) = 0.2.$$

Step 2: 团节点  $[XE]$  储存的信度为  $m(E = \text{是}) = 1, m(E = \text{否}) = 0$ , 由  $E|X$  条件信度参数可知,  $X \leftarrow E$  为反向推理, 由式(12)可得团节点  $[XE]$  联合信度  $V_3$  的取值, 再由式(14)可得

$$M_{3 \rightarrow 1}(E = \text{是}) = 1, M_{3 \rightarrow 1}(E = \text{否}) = 0.$$

Step 3: 团节点  $[EBD]$  储存的信度为  $m(D = \text{是}) = 1$ , 由  $D|EB$  条件信度参数可知,  $D \leftarrow EB$  为反向推理, 由Step 2方法可得到  $M_{4 \rightarrow 6}(E, B)$  的取值为

$$\begin{aligned} M_{4 \rightarrow 6}(E = \text{否}, B = \text{否}) &= 0.1, \\ M_{4 \rightarrow 6}(E = \text{是}, B = \text{否}) &= 0.3, \end{aligned}$$

$$M_{4 \rightarrow 6}(E = \text{否}, B = \text{是}) = 0.3,$$

$$M_{4 \rightarrow 6}(E = \text{是}, B = \text{是}) = 0.3.$$

Step 4: 团节点  $[SLB]$  储存的信度为  $m(S = \text{是}) = 1$ , 由  $LB|S$  条件信度参数可知,  $S \rightarrow LB$  为正向推理, 由Step 1方法可得到  $M_{5 \rightarrow 6}(L, B)$  的取值为

$$M_{5 \rightarrow 6}(L = \text{否}, B = \text{否}) = 0.1,$$

$$M_{5 \rightarrow 6}(L = \text{否}, B = \text{是}) = 0.2,$$

$$M_{5 \rightarrow 6}(L = \text{是}, B = \text{否}) = 0.4,$$

$$M_{5 \rightarrow 6}(L = \text{是}, B = \text{是}) = 0.3.$$

Step 5: 由团节点  $[LEB]$  处储存的联合信度  $V_6$  和式(17)可得  $M_{6 \rightarrow 1}(L, E)$  的取值为

$$M_{6 \rightarrow 1}(L = \text{否}, E = \text{否}) = 0.12,$$

$$M_{6 \rightarrow 1}(L = \text{否}, E = \text{是}) = 0.18,$$

$$M_{6 \rightarrow 1}(L = \text{是}, E = \text{否}) = 0.28,$$

$$M_{6 \rightarrow 1}(L = \text{是}, E = \text{是}) = 0.42.$$

取答案阶段.

由  $m(T) = [V_1 \oplus (M_{2 \rightarrow 1}(T) \oplus M_{6 \rightarrow 1}(L, E))]^{dT}$  得到变量  $L, E, B$  的基本信任分配值. 与前面实验步骤一样, 可以计算出分别选取团节点  $[LEB]$ 、 $[DEB]$  和  $[SLB]$  为推理枢纽的各个变量的证据信度, 如表6所示.

表6 基于团树传播算法得到的各个变量的信任分配

团节点	混合DSmT			改进的混合DSmT			
	$m(\text{是})$	$m(\text{否})$	$m(\Theta)$	$m(\text{是})$	$m(\text{否})$	$m(\Theta)$	
$[TLE]$	$T$	0.0864	0.3411	0.5724	0.1	0.4	0.5
	$L$	0.3702	0.0979	0.5318	0.35	0.15	0.5
	$E$	0.654	0.039	0.3070	0.6	0.12	0.28
$[LEB]$	$L$	0.3702	0.0979	0.5318	0.35	0.15	0.5
	$E$	0.6540	0.039	0.3070	0.6	0.12	0.28
	$B$	0.5363	0.1296	0.3340	0.64	0.14	0.22
$[DEB]$	$D$	0.6028	0	0.3972	1	0	0
	$E$	0.555	0.1297	0.3153	0.6	0.12	0.28
	$B$	0.4417	0.2312	0.3270	0.540	0.24	0.22
$[SLB]$	$S$	0.5903	0	0.4097	1	0	0
	$L$	0.5637	0.1530	0.2833	0.35	0.15	0.5
	$B$	0.4090	0.2720	0.3190	0.46	0.26	0.28

### 3.2 实例结果分析

由表6可见, 含有变量  $L, E, B$  的团节点  $[TLE]$ 、 $[LEB]$ 、 $[DEB]$  和  $[SLB]$  通过边际化操作后得到的  $L, E, B$  基本信任分配是一致的, 所以基于团树传播算法需要得到哪个感兴趣变量的信任值, 只要随意选取一个含有该变量的团作为推理枢纽即可. 比较  $T, L, B$  的信度可知, 医生对支气管炎的支持度最高, 然后是肺癌, 患肺结核的可能性最小.

改进组合规则前后各个变量未知集的比较如图5所示. 由图5可见, 表6改进的混合DSmT组合规

则中,  $m(\theta)$  那一系列的基本信任分配基本都小于混合 DSmT 组合规则中  $m(\theta)$  一系列的基本信任分配, 即利用改进的基于联合空间上的混合 DSmT 组合规则得到变量的未知程度小于利用混合 DSmT 融合规则得到的结果, 这样可以得到更加准确的医学诊断结果.

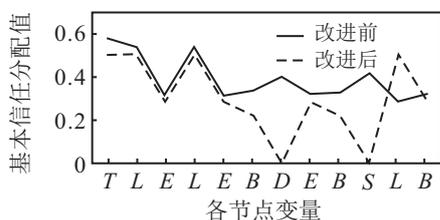


图5 改进组合规则前后各个变量未知集的比较

## 4 结论

本文根据团树传播算法可以应用在多连通网络模型的特点, 将其应用于证据网络进行不确定性信度推理. 以联合信度为团节点间参数的方式, 得到了任意一个感兴趣变量的值, 避免了多连通情况下消息往复传播的问题, 进行了有效的不确定性推理, 改进了 DSmT 融合规则, 减小了变量的未知程度, 增大了变量的确定性, 使得信度合成更加准确, 也为联合空间上的融合提供了一种更优的合成规则. 最后以胸腔医学诊断问题为例, 验证了所提出方法是一种行之有效的推理方法.

## 参考文献(References)

- [1] Hong Xu. Reasoning in evidential networks with conditional belief functions[J]. Int J of Approximate Reasoning, 1996, 14(2/3): 155-185.
- [2] Smets P. The combination of evidence in the transferable belief model[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 1990, 12(5): 447-458.
- [3] Smet P, Kennes R. The transferable belief model[J]. Artificial Intelligence, 1994, 66(4): 191-234.
- [4] Su X, Mahadevan S, Xu P, et al. Handling of dependence in dempster-shafer theory[J]. Int J of Intelligent Systems, 2015, 30(4): 441-467.
- [5] Attoh-Okine N O. Aggregating evidence in pavement management decision-making using belief functions and qualitative Markov tree[J]. IEEE Trans on Systems, Man, and Cybernetics, Part C: Applications and Reviews, 2002, 32(3): 243-251.
- [6] 厉海涛, 金光, 周经伦, 等. 贝叶斯网络推理算法综述[J]. 系统工程与电子技术, 2008, 30(5): 935-939. (Li H T, Jin G, Zhou J L, et al. Survey of bayesian network inference algorithms[J]. Systems Engineering and Electronic Technology, 2008, 30(5): 935-939.)
- [7] Huang Cecil, Darwieche A. Inference in belief networks: A procedural guide[J]. Int J of Approximate Reasoning, 1996, 15(3): 225-263.
- [8] 张连文, 郭海鹏. 贝叶斯网引论[M]. 北京: 科学出版社, 2006: 107-124. (Zhang L W, Guo H P. An introduction to Bayesian networks[M]. Beijing: Science Press, 2006: 107-124.)
- [9] 刘启元, 张聪, 沈一栋. 信度网推理方法及问题(下)[J]. 计算机科学, 2001, 28(2): 115-118. (Liu Q Y, Zhang C, Shen Y D. Inference in belief network-methods and problems(2)[J]. Computer Science, 2001, 28(2): 115-118.)
- [10] 姜江. 证据网络模型及其推理算法[J]. 系统工程理论与实践, 2015, 35(4): 984-990. (Jiang J. Evidential network model and reasoning approach[J]. Systems Engineering — Theory & Practice, 2015, 35(4): 984-990.)
- [11] 李中杰, 徐世友, 刘万全, 等. 基于条件信任函数的证据网络在综合敌我识别中的应用[J]. 计算机工程与应用, 2011, 47(8增): 289-294. (Li Z J, Xu S Y, Liu W Q, et al. Integrated IFF in evidential networks with conditional belief function[J]. Computer Engineering and Applications, 2011, 47(8S): 289-294.)
- [12] 李贤, 陈志刚, 徐世友, 等. 联合信度推理证据网参数学习[J]. 控制与决策, 2014, 29(8): 1419-1423. (Li X, Chen Z G, Xu S Y, et al. Parameters learning in evidential network deducing using unite-believe value[J]. Control and Decision, 2014, 29(8): 1419-1423.)
- [13] Shenoy P P. Valuation-based systems: A framework for managing uncertainty in expert systems[C]. Fuzzy Logic for the Management of Uncertainty. New York: John Wiley Sons, 1992: 83-104.
- [14] Boutheina Ben Yaghlane, Khaled Mellouli. Inference in directed evidential networks based on the transferable belief model[J]. Int J of Approximate Reasoning, 2008, 48(2): 399-418.
- [15] 郭强, 关欣, 潘丽娜, 等. 一种基于混合参数和 DSmT 的证据网络多连通结构推理方法[J]. 中国电子科学研究院学报, 2015, 10(1): 67-74. (Guo Q, Guan X, Pan L N, et al. An inference method for evidential networks of multiply connected structure based on mixed parameters and dsmt theory[J]. J of CAEIT, 2015, 10(1): 67-74.)
- [16] Florentin S, Jean D. DSmT 理论及其在信息融合中的应用(文集)[M]. 北京: 国防工业出版社, 2011: 54-85. (Florentin S, Jean D. Advances and applications of dsmt for information fusion(collected works)[M]. Beijing: National Defense Industry Press, 2011: 54-85.)

(责任编辑: 郑晓蕾)