

一种基于非单调逻辑的模型管理方法

蓝红兵

费奇

(清华大学经管学院,北京 100084)

(华中理工大学系统所,武汉 430074)

摘要

本文讨论了模型管理中不确定性的表达、传递、证据合成以及问题求解过程，提出了一种基于非单调逻辑的模型管理方法：将模型结构形式的不确定性表示为由建模者或领域专家对问题结构中未知或随机情形所作假设集支持的可能性命题；模型之间不确定性关系的管理通过对假设环境的真值(一致性)保持和信度调整过程来实现，其依据是在问题求解过程中出现的冲突情形或者是由决策人提供的有关命题或次判断。

关键词：模型管理, 非单调逻辑, 假设环境, 不确定性, 次判断。

一、引言

在不良结构问题的建模过程中,由于问题结构的复杂性、随机性以及人们认识上或者是建模手段的局限性,往往会涉及到大量的不确定性因素。模型中的不确定性反映在模型结构、模型变量之间相互影响的映射(输入/输出对偶)关系以及模型参数(包括决策变量)的赋值上。考虑到建模环境中的不确定性,建模者对不确定性情形的了解是不完全的,建模者一般会根据自己或有关专家的经验和判断对未知或随机的问题作出猜测和假设,并在此基础上对问题和模型的结构进行分析和判断,提出试验性的模型框架,并在获得进一步的信息时(例如,由试验模型推导出的冲突命题或者是对试验模型的有效性检验结果),对试验模型框架作相应的修正。由于对同一问题的建模可能会存在多种形式的模型结构,笔者将模型结构形式的不确定性表示为一组由多种假设环境(Assumption Environments)支持的可能性命题,而模型变量之间映射关系的成立依赖于某种可能的模型结构形式,这里,映射关系的不确定性是指映射关系成立的可能性。在本文的讨论中,模型的定义以模型结构形式和变量之间的映射关系为基础,而模型参数作为模型的输入数据或先验信息处理。

用来表示变量或命题之间不确定性关系的图论方法主要有信度网络(Belief Networks)、推理网络(Infleunce Networks)和相关图(Influence Diagrams)等,这些方法以经典的 Bayes 概率为基础,要求完整地给出整个可能性信息空间上的概率分布。由于建模和决策支持只能是一个信息逐步补充和完善的过程,一般不可能完整和准确地给出

模型中各映射关系成立的概率以及模型输入变量的先验概率分布,所以,已有的图论方法不能很好地解决不完全信息结构下的模型管理问题。

证据理论^[1]通过引入基本概率分配函数、信任度和似然度来直观地表示论域中不确定性证据的强度和信息的未知程度,与 Bayes 概率方法比较,它能更有效、更准确地反映人们进行主观判断时的一些特点。另外,由嵌套在模型算法中的其它不确定性计算方法给出的结论也可以转换为证据理论中基本概率分配函数的形式^[2]。非单调(缺省)逻辑^[3,4]是专家系统中用来处理不确定性和不完全信息的非数值方法,而非单调概率(Nonmonotonic Probabilistic)^[5]进一步将证据理论的计算方法引入非单调逻辑系统中,为对基于假设的推理过程的控制,即对假设环境的信度计算和调整提供了数值计算方法,非单调概率将由新的信息引起的冲突视为证据的补充,冲突的信息和命题用来作为对假设环境的信度进行重新分配的依据。非单调概率为不确定性环境下的模型管理提供了良好的工具,模型库中不确定性的管理可以通过对假设环境的真值保持(Truth maintenance)以及对(模型或变量之间)映射关系成立的信度进行分配和调整的过程来实现。

二、模型管理与问题求解

1. 模型库中映射关系的描述

模型管理包括模型输入/输出属性关系的管理和不确定性的管理两个方面,从不确定性分析的角度看,多个模型变量之间的映射关系集构成模型库中不确定性关系的局部网络,并最终反映在模型输入/输出变量之间的不确定性对偶关系上。模型管理中不确定性关系网络的结构如图 1 所示:关系网络中的节点表示模型变量,弧表示变量之间的映射关系。

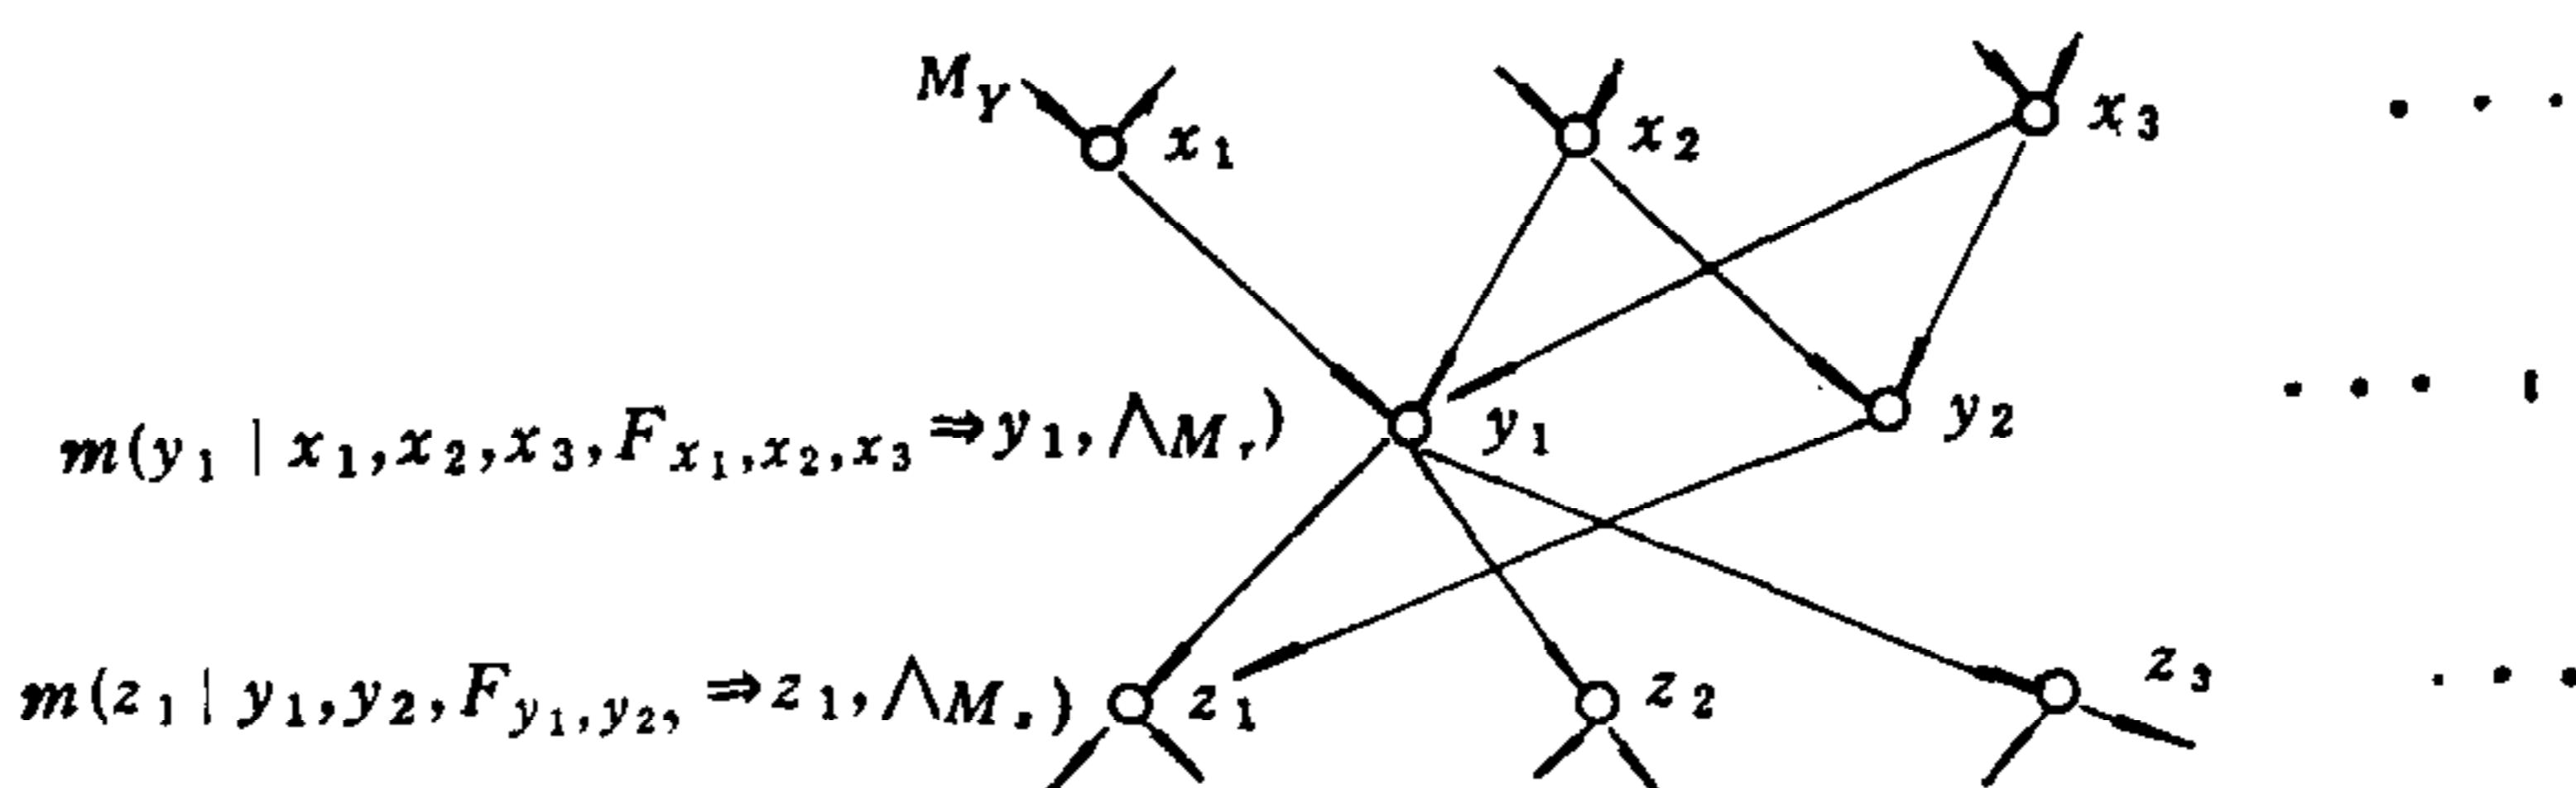


图 1 不确定性关系网络

支持某种映射关系成立的假设环境可以看成是这种映射关系成立的前提条件,假设环境的信度调整可以影响到不确定性关系网络的结构形式。本文将映射关系表示为含有不确定性因子的五元组 $M: \langle \mathbf{x}, \mathbf{y}, F_{\mathbf{x} \Rightarrow \mathbf{y}}, P_F, \Lambda_M \rangle$, 其中, \mathbf{x}, \mathbf{y} 分别为关系链中的输入、输出变量集或命题集; $F_{\mathbf{x} \Rightarrow \mathbf{y}}$ 指从 $\mathbf{x} \Rightarrow \mathbf{y}$ 的映射方式,可以是函数、算法(如线性规划、回归分析等)或逻辑的形式; P_F 表示映射关系 $F_{\mathbf{x} \Rightarrow \mathbf{y}}$ 中参数或先验信息的不确定性;而 Λ_M 用来表示支持关系链 M 成立的假设环境,称为 M 的标签(label)。由于存在输入/输出属性关系回路的多个映射关系(模型)可以表示为映射关系集(模型集),而本文仅考

虑这一关系集或模型集的输入/输出属性。所以，在下面的讨论中，假定关系网络中不存在变量或命题之间的依赖关系回路。

2. 问题求解与真值保持过程

基于假设的真值保持系统 (Assumption-based Truth Maintenance System, 简称 ATMS)^[4] 是一种比较成熟的非单调逻辑系统，它能同时对多个互相冲突的命题进行真值保持以及明显地区分问题求解与真值保持这两个过程，是用来进行命题之间相关性 (dependency) 分析的有效工具，可以较好地适用于模型管理中对假设环境的真值保持过程。现用 ATMS 中的节点来记录模型库中的可能性命题(假设环境和映射关系)，各假设之间相互独立，且不依赖于其它节点成立；ATMS 中的次判断 (justifications, 原意是“判义”) 用来进行节点之间的相关性推理，例如，规则 $x \wedge^1 A \rightarrow y$ 可以表示为次判断： $x, A \Rightarrow y$ ；每一节点的标签是指支持该节点成立的假设环境(假设集)，用 ATMS 中的 nogood 符号表示包含冲突子集的假设集，即不良假设集；模型管理中的次判断和不良假设集既可以在建模过程中设定，也可以在问题求解过程中进行记录和调整。在满足假设环境一致性条件的情况下，对同一数据或命题赋值的计算或推理可能会存在多种可能的模型结构形式，这些模型为数据赋值或命题的成立提供了不同途径的证据支持，这样，在证据合成中可能会出现证据不相容的情况，即由不同模型提供的结论是完全冲突的，这时，可以认为支持这些模型成立的假设环境是不良的。不良假设集的提出为假设环境信度的重新分配提供了新的证据，用户对问题求解结果所作的分析和判断以及相应的领域知识也可以表示为次判断的形式，为模型库中不确定性关系的管理提供了依据，这一过程如图 2 所示。

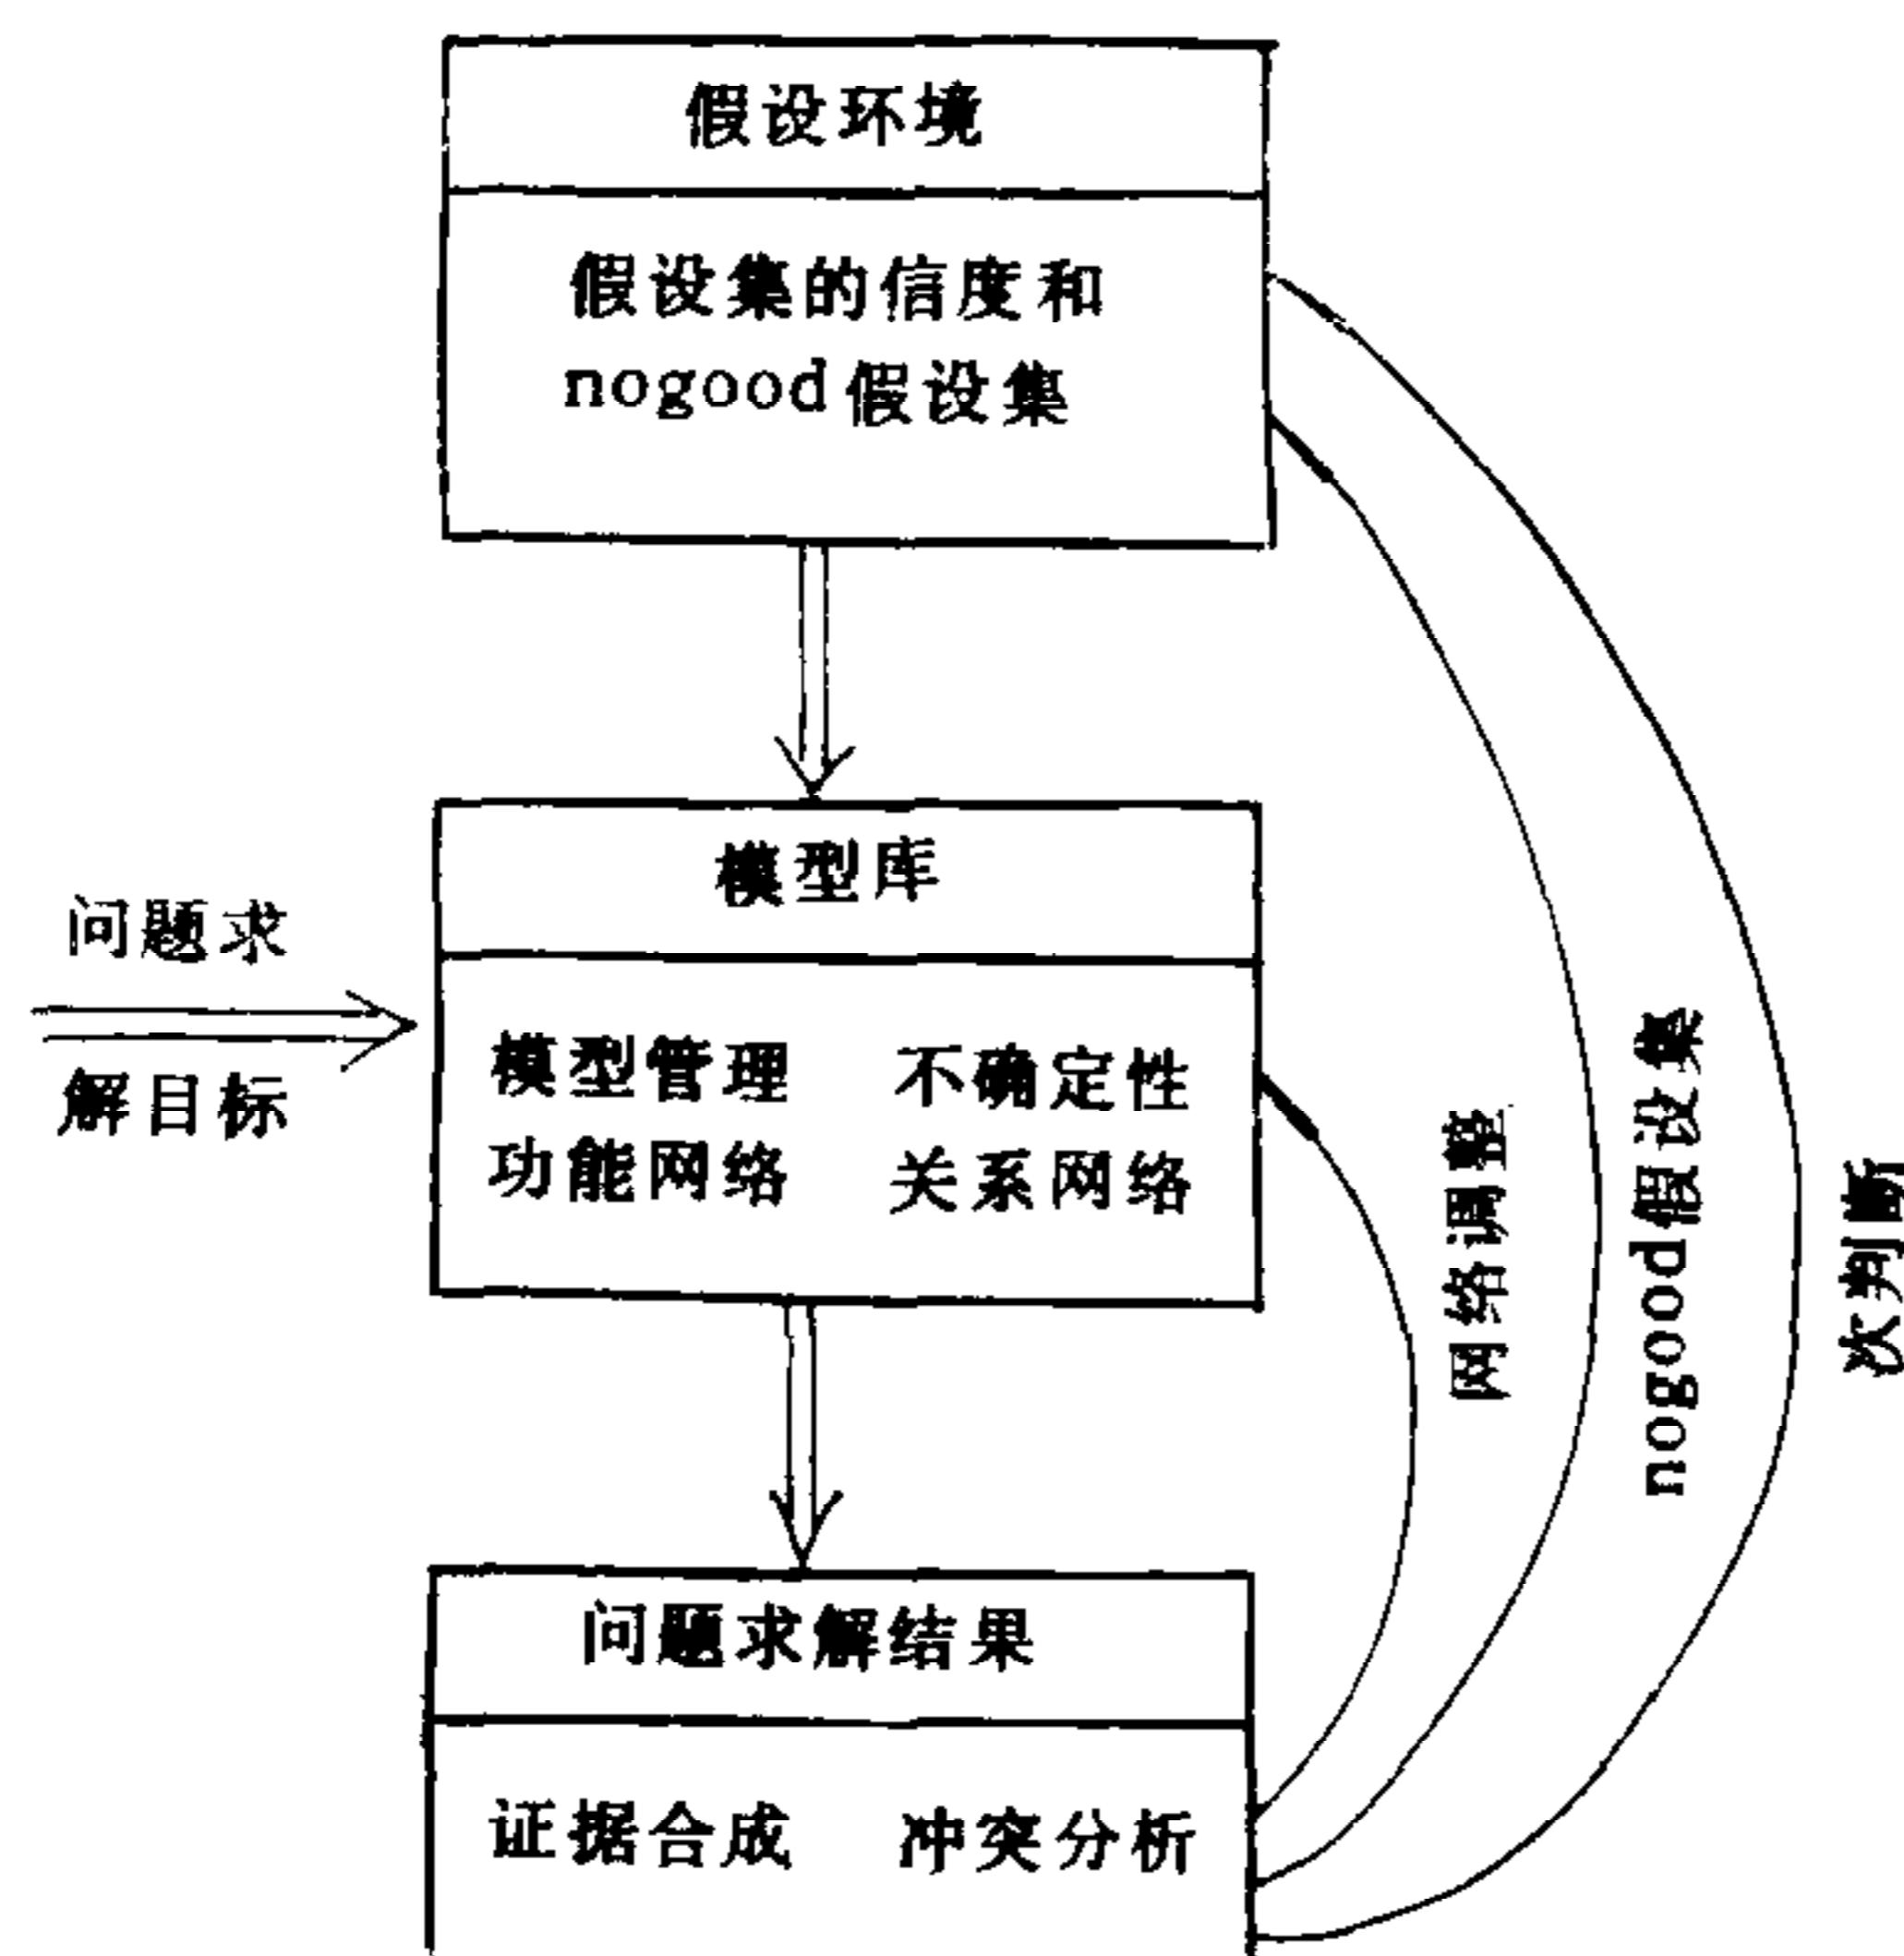


图 2 问题求解与真值保持过程

次判断

在满足假设环境一致性条件的情况下，对同一数据或命题赋值的计算或推理可能会存在多种可能的模型结构形式，这些模型为数据赋值或命题的成立提供了不同途径的证据支持，这样，在证据合成中可能会出现证据不相容的情况，即由不同模型提供的结论是完全冲突的，这时，可以认为支持这些模型成立的假设环境是不良的。不良假设集的提出为假设环境信度的重新分配提供了新的证据，用户对问题求解结果所作的分析和判断以及相应的领域知识也可以表示为次判断的形式，为模型库中不确定性关系的管理提供了依据，这一过程如图 2 所示。

三、模型库中不确定性关系的管理

1. 关系网络中的信度计算与传递

现将模型变量或命题的所有可能的赋值集合表示为有限论域 Θ ，论域 Θ 是穷举的，并且 Θ 中的元素是互相排斥的， 2^Θ 表示论域 Θ 的幂集空间，证据理论将论域 Θ 上的不确定性表示为 2^Θ 上的基本概率分配函数 $m: 2^\Theta \rightarrow [0, 1]$ ，并满足：

$$m(\emptyset) = 0, \quad \sum_{A \subseteq \Theta} m(A) = 1.$$

¹⁾ 合取 (conjunction) 词，用来表示逻辑与。

模型输出变量赋值的基本概率分配同时取决于输入数据(模型参数)的不确定性和映射关系的不确定性,在模型库中的信度传递过程中,可将这两种不确定性视为两种独立的不确定性因素,由映射关系 M 给出的输出变量 y_i 的条件概率分配函数为

$$m(y_i | x_1, \dots, x_n, \Lambda_M) = \sum_{\substack{F \\ M(x_1, \dots, x_n, P_F) \Rightarrow y_i}} P_r(P_F). \quad (1)$$

证据理论中信度的传递是通过论域的扩张和限制实现的, 条件概率分配函数 $m(y_i | x_1, \dots, x_n, \Lambda_M)$ 定义在乘积空间 $\Theta_{x_1} \times \dots \times \Theta_{x_n} \times \Theta_M \times \Theta_{y_i}$ 上, 条件概率分配函数 $m(y_i | \Lambda_M)$ 由下式给出:

$$m(y_i | \Lambda_M) = \sum_{\substack{x'_j, x''_j \in \Theta_{x_j} \\ j=1, \dots, n \\ x''_1 \times \dots \times x''_n \in x'_1 \times \dots \times x'_n}} m(y_i | x'_1, \dots, x'_n, \Lambda_M) \times m(x''_1, \dots, x''_n), \quad (2)$$

式中 Θ_{x_j} 为变量 x_j 的论域, 显然有 $m(\phi | \Lambda_M) = 0$; $\sum_{y'_i \in \Theta_{y_i}} m(y'_i | \Lambda_M) = 1$.

2. 模型求解结果的信度合成

在问题求解过程中, 根据关系网络中各个模型的输入数据是否已知, 可以逐步激活网络中的节点。由于数据集 D_Y 可能同时包含在多个模型 M_1, \dots, M_k 的输出数据集中(此时, 将模型视为一种映射关系), 模型 M_1, \dots, M_k 均以某种形式为 D_Y 的赋值提供相应的证据支持, 而 D_Y 赋值的基本概率分配将通过对这 k 种证据的合成来获得。所以, 在问题求解过程中的每一步, 都应将由该步所激活模型提出的证据存入相应的暂存表中, 并与暂存表中已有的证据合成, 如果已经获得了关于 D_Y 赋值的所有证据, 则将暂存表中关于 D_Y 赋值的基本概率分配作为问题求解过程中的已知信息。

模型 M_i 的标签表 Λ_{M_i} 的一般形式为 $\Lambda_{M_i}: \{A_1, \dots, A_m\}$, 其中 A_i 为假设集 $\{A_{i_1}, \dots, A_{i_n}\}$, 且有 $A_1 \vee^1 \dots \vee A_m \Rightarrow M_i, A_{i_1} \wedge \dots \wedge A_{i_n} \Rightarrow A_i, i = 1, \dots, m$ 。模型 M_i 成立的信度由下式给出:

$$\text{Bel}(\{\Lambda_{M_i}\}) = P_r(\Lambda_{M_i} \cap \text{!nogood}^i) / (1 - P_r(\text{nogood}^i)), \quad (3)$$

式中 nogood^i 是指与标签 Λ_{M_i} 的信度计算有关的不良假设集, !nogood^i 表示 nogood^i 的补集, 信度 $\text{Bel}(\{\cdot\})$ 的计算详见文献[5]。标签表 $\Lambda_{M_1}: \langle \alpha_1, \dots, \alpha_{m_1} \rangle$ 与 $\Lambda_{M_2}: \langle \beta_1, \dots, \beta_{m_2} \rangle$ 的交集和合取分别为

$$\Lambda_{M_1} \cap \Lambda_{M_2} = \bigcup_{\substack{i \in \{1, \dots, m_1\} \\ j \in \{1, \dots, m_2\}}} \{\alpha_i \cap \beta_j\}, \quad (4)$$

$$\Lambda_{M_1} \wedge \Lambda_{M_2} = \bigvee_{\substack{\text{假设集 } \alpha_i \text{ 与 } \beta_j \text{ 一致,} \\ \text{即 } P_r(\alpha_i \wedge \beta_j) \neq 0, \\ i \in \{1, \dots, m_1\}, j \in \{1, \dots, m_2\}}} \{\alpha_i, \beta_j\}^* \quad (5)$$

在数据集 D_Y 的证据合成时, 首先将模型 M_1, \dots, M_k 按照其标签表的一致性划分
为 $M_{1,1}, \dots, M_{1,s_1}, \dots, M_{r,1}, \dots, M_{r,s_r}$, $\sum_{i=1}^r s_i = k$, 标签表 $\Lambda_{\tilde{M}_i}: \{\Lambda_{M_{i,1}} \wedge \dots \wedge \Lambda_{M_{i,s_i}}\}$

1) 析取词(disjunction), 表示逻辑与。

非空,即存在能同时支持模型 $M_{i,1}, \dots, M_{i,r_i}$ 成立的假设集,并且,假设集 $\{\Lambda_{\tilde{M}_i}, \Lambda_{\tilde{M}_j}\}$ 构成不良假设集,即 $P_r(\Lambda_{\tilde{M}_i} \wedge \Lambda_{\tilde{M}_j}) = 0$, 证据合成的过程如下:

步骤 1. 在一致性假设集 $\Lambda_{\tilde{M}_i}$ 支持下,对由模型 $M_{i,1}, \dots, M_{i,r_i}$ 提供的证据进行非独立的证据合成^[6]:

$$m_i(D_Y | \Lambda_{\tilde{M}_i}) = \overline{\bigoplus_{j=1}^{r_i}} m_j(D_Y | \Lambda_{M_{i,j}}). \quad (6)$$

步骤 2. 如果在证据合成过程中出现完全冲突的两种证据 $m_I(\cdot), m_J(\cdot), I \neq J$, 且有: $\sum_{D_Y^I \cap D_Y^J \neq \emptyset} m_I(D_Y^I | \Lambda_{M_{i,I}}) * m_J(D_Y^J | \Lambda_{M_{i,J}}) = 0$, 这时, 可认为冲突证据的出现是由于对假设环境信度的错误分配引起的,这样,支持模型 $M_{i,I}, M_{i,J}$ 成立的假设集 $\{\Lambda_{M_{i,I}}, \Lambda_{M_{i,J}}\}$ 是不良的。根据证据合成过程中新提出的不良假设集,重新对多个模型 M_1, \dots, M_k 进行划分,转步骤 1. 由于在问题求解过程中,不良假设集的提出是递增的,并且对假设环境结构的划分是逐步细化的,所以,对假设环境的信度调整过程是可以收敛的。

步骤 3. 由假设集 $\Lambda_{\tilde{M}_i}$ 支持的模型集 $\tilde{M}_i: \{M_{i,1}, \dots, M_{i,r_i}\}, i = 0, \dots, r$, 可以看成是对数据集 D_Y 赋值的证据收集方式论域 Θ_M 的一个分割。这里, \tilde{M}_0 表示未知的模型集, $\Lambda_{\tilde{M}_0} = \Gamma(\Lambda_{\tilde{M}_1} \vee \dots \vee \Lambda_{\tilde{M}_r})$, 由全概率公式,可给出合成后 D_Y 赋值的基本概率分配:

$$m(D_Y) = \sum_{i=0}^r m_i(D_Y | \Lambda_{\tilde{M}_i}) * \text{Bel}(\{\Lambda_{\tilde{M}_i}\}), \quad (7)$$

其中

$$\text{Bel}(\{\Lambda_{\tilde{M}_0}\}) = 1 - \sum_{i=1}^r \text{Bel}(\{\Lambda_{\tilde{M}_i}\}), m_0(D_Y | \Lambda_{\tilde{M}_0}) = \begin{cases} 0, & D_Y \neq \Theta_{D_Y}, \\ 1, & D_Y = \Theta_{D_Y}. \end{cases}$$

四、实例分析

现以某地区教育投资量的预测为例,说明模型管理中的信度计算和合成方法。假定预测期间教育投资量的大小取决于该地区的财政收入,根据调查结果,可以提出两种可行的预测模型结构 M_1, M_2 ,如表 1 所示。模型中参数 k, k_0, k_1 和输入数据 $I_{NC}(t)$ 的基本概率分配分别为 $m(k), m(k_0), m(k_1), m(I_{NC}(t))$,由(2)式有

$$m_1(\bar{I}_{NV}(t) | \Lambda_{M_1}) = \sum_{\substack{I,J \\ \bar{k}^I * \bar{I}_{NC}^J(t) \in \bar{I}_{NV}(t)}} m(\bar{k}^I) \times m(\bar{I}_{NC}^J(t)), \quad (8)$$

$$m_2(\bar{I}_{NV}(t) | \Lambda_{M_2}) = \sum_{\substack{I,J,k \\ (\bar{k}_0^I + \bar{k}_1^J * t) * \bar{I}_{NC}^k(t) \in \bar{I}_{NV}(t)}} m(\bar{k}_0^I) \times m(\bar{k}_1^J) \times m(\bar{I}_{NC}^k(t)),$$

式中 \bar{x} (如 $\bar{I}_{NV}(t)$) 表示数据 x 的赋值区间。由于假设集 $\{\Lambda_{M_1}, \Lambda_{M_2}\}$ 构成不良假设集,

输出数据 $I_{NV}(t)$ 赋值分布的基本概率分配函数由下式给出：

$$m(\bar{I}_{NV}(t)) = \begin{cases} \sum_{i=1}^2 m_i(\bar{I}_{NV}(t) | A_{M_i}) \times \text{Bel}(\{A_{M_i}\}), \\ \quad \bar{I}_{NV}(t) \neq [\bar{I}_{NV}^{\min}(t), \bar{I}_{NV}^{\max}(t)], \\ \left(1 - \sum_{i=1}^2 \text{Bel}(\{A_{M_i}\})\right) + \sum_{i=1}^2 m_i(\bar{I}_{NV}(t) | A_{M_i}) \times \\ \quad \text{Bel}(\{A_{M_i}\}), \\ \quad \bar{I}_{NV}(t) = [\bar{I}_{NV}^{\min}(t), \bar{I}_{NV}^{\max}(t)], \end{cases}$$

其中

$$\begin{aligned} \text{Bel}(\{A_{M_1}\}) &= P_r(A_1, A_2, \neg A_3) / (1 - P_r(A_2) \times P_r(A_3)), \\ \text{Bel}(\{A_{M_2}\}) &= P_r(A_1, \neg A_2, A_3) / (1 - P_r(A_2) \times P_r(A_3)). \end{aligned}$$

假如在预测过程中有一项报告 r 说明预测期间教育政策稳定的假设是不可靠的，用假设 A_4 表示报告 r 成立，因此，这一冲突的命题可以表示为次判断： $r, A_4 \Rightarrow \neg A_1$ ，同时提出了

表 1 实例

模型结构形式 M_1, M_2	假设集 A_1, A_2, A_3
$M_1: I_{NV}(t) = K \cdot I_{NC}(t)$, $A_{M_1}: \{A_1, A_2\}$; $M_2: I_{NV}(t) = (K_0 + K_1 \cdot t) \cdot I_{NC}(t)$, $A_{M_2}: \{A_1, A_3\}$; $I_{NV}(t)$: t 年教育投资量; $I_{NC}(t)$: t 年财政收入总量, $I_{NC}(0) = 1$; $t = 1, 2, \dots, 20$	A_1 : 教育投资政策稳定; A_2 : $I_{NV}(t)$ 占 $I_{NC}(t)$ 的比例为一常数; A_3 : $I_{NV}(t)$ 与 $I_{NC}(t)$ 的比例逐年提高; nogood 假设集: $\{A_1, \neg A_1\}$, $\{A_2, \neg A_2\}$, $\{A_3, \neg A_3\}$, $\{A_4, \neg A_4\}$

新的不良假设集 $\{A_1, A_4\}$ ，这时，将信度 $\text{Bel}(\{A_{M_1}\})$, $\text{Bel}(\{A_{M_2}\})$ 修改为

$$\text{Bel}(\{A_{M_1}\}) = P_r(A_1, A_2, \neg A_3, \neg A_4) / (1 - P_r(\text{nogood}))$$

$$\text{Bel}(\{A_{M_2}\}) = P_r(A_1, \neg A_2, A_3, \neg A_4) / (1 - P_r(\text{nogood}))$$

其中

$$\begin{aligned} P_r(\text{nogood}) &= P_r(A_2) \times P_r(A_3) \\ &+ P_r(A_1) \times P_r(\neg A_2) \times P_r(A_4) \\ &+ P_r(A_1) \times P_r(A_2) \times \\ &\times P_r(\neg A_3) \times P_r(A_4), \end{aligned}$$

对信度 $\text{Bel}(\{A_{M_1}\})$, $\text{Bel}(\{A_{M_2}\})$ 的调整

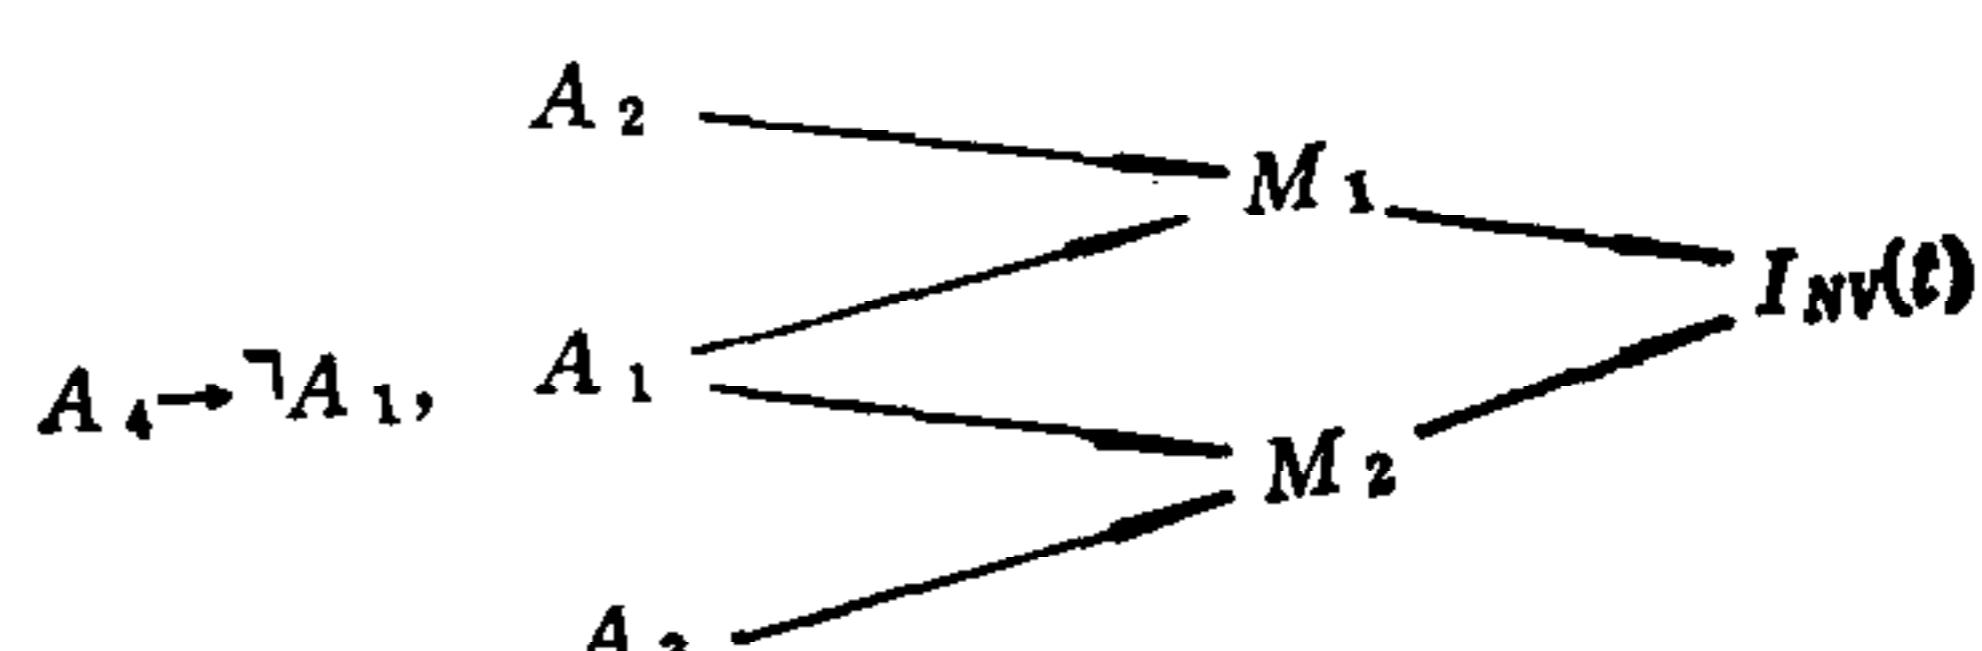


图 3 由冲突信息引起的信度调整过程

将改变输出数据 $I_{NV}(t)$ 的基本概率分配函数 $m(\bar{I}_{NV}(t))$ ，信度调整过程如图 3 所示。

参 考 文 献

- [1] Shafer G. A., A Mathematical Theory of Evidence, Princeton University Press, NJ, (1986).
- [2] Dubois, D. and Prade, H., On Several Representations of an Uncertain Body of Evidence, in: Gupta M. M. et al. (Eds.), Fuzzy Information and Decision Process, North-Holland, Amsterdam, (1982), 167—182.
- [3] McDermott, D. and Doyle, J., Nonmonotonic Logic I, *Artificial Intelligence*, 13(1980), 41—72.
- [4] de Kleer J., An Assumption-based TMS, *Artificial Intelligence*, 28(1986), 127—161.
- [5] Laskey, K. B., Assumptions, Beliefs and Probabilities, *Artificial Intelligence*, 43(1989), 65—77.
- [6] Ling, X. N. and Rudo, W. G., Combining Options from Several Experts, *Applied Artificial Intelligence*, 3 (1989), 439—452.

A NONMONOTONIC LOGIC-BASED METHOD FOR MODEL MANAGEMENT

LAN HONGBING

(Institute of Economics & Management Tsinghua University, Beijing 100084)

FEI QI

(Institute of Systems Engineering, Huazhong University of Science & Technology, Wuhan 430074)

ABSTRACT

This paper presents a nonmonotonic logic-based approach to the problem of model management in uncertain environments. The proposed algorithm for uncertainty analysis provides a mechanism for uncertainty representation, propagation, evidence combination and problem solving under uncertainties. Furthermore, uncertainties about model structures, i.e., the probabilities of possible model structures, are represented by probability propositions supported by sets of ATMS's assumptions about uncertain situations. Hence, the management of uncertain causal link between models is realized in the processes of truth maintenance, belief assignment and adjustment about assumptions' environment, wherein, conflict situations presented in problem solving processes and related ATMS justifications about the results of problem solving are taken as new evidences for truth maintenance and the adjustment of degrees of belief.

Key words: Model management; nonmonotonic logic; assumptions' environment; uncertainty; justifications.



蓝红兵 1967年生,1991年于武汉华中理工大学获工学博士学位。现在清华大学经济管理学院系统工程室工作。主要的研究集中在决策支持系统中的两个核心问题:建模支持和智能型的图形界面上,并且在软件开发方面积累了一定的经验。



费奇 1939年生,1961年毕业于哈尔滨工业大学,现任华中理工大学教授。曾从事自动控制理论、自动化仪表、系统工程等学科的教学与科研工作。现从事决策支持理论、智能计算机应用、教育系统工程、物资管理系统、采矿业管理系统等方面的研究工作。