

# 包含度理论

张文修 徐宗本 梁怡 梁广锡

(西安交通大学, 西安, 710049) (香港中文大学)

**摘要** 不确定性是复杂系统的特征。在人工智能与专家系统中, 不确定性的研究越来越具有重要意义。Zadeh<sup>[1]</sup>于1965年提出模糊集, 把经典集合扩充到模糊集合, 从而解决了“对象”的不确定性。本文引进了包含度的概念, 解决了“关系”的不确定性。同时指出, 包含度不仅是各种不确定性推理方法的概括, 而且解决了知识获取与矛盾规则排除两个重要问题。

**关键词** 包含度; 不确定性推理; 知识获取。

在一个复杂系统中, 有许多不确定性的来源。首先, 人们提出的问题常常是不精确的, 不精确的问题导致不精确的结果; 第二, 获取的信息不完全, 知识获取的过程也是不精确的; 第三, 推理的过程也是不确定的, 不确定性的推理过程导致不确定性的结论。随着人们研究范围的扩大, 研究的系统越来越复杂, 系统的复杂性与经典数学的精确描述越来越不协调。Zadeh<sup>[1]</sup>引入的模糊集合, 将经典集合模糊化, 使具有分明边界的集合变为具有不分明边界的模糊集合。模糊集合理论在复杂系统中得到了成功地应用, 特别是在模糊控制中, 取得了显著成果。包含度是将“包含关系”度量化, 从而包容了“关系”的不确定性。

在经典包含关系中, 要么“包含”, 要么“不包含”, 二者必居其一。这种极端的分界, 将“关系”过于简化。比如“会飞的鸟”显然是“鸟”, 因为“会飞的鸟”是“鸟”的一部分。但是“鸟”并不一定是“会飞的鸟”, 按照传统的“包含关系”, 我们就不能得到“鸟会飞”的结论, 因为确实有某些种类的鸟是不会飞的鸟, 这对人们思考问题是一个很大的限制。事实上有99%以上的鸟都会飞, 也即“鸟”包含于“会飞的鸟”的包含度为0.99以上。正因为这样, 人们可以冒着犯一小点错误的危险, 到处使用“鸟会飞”的断语。由于在复杂系统中, 不确定性越来越占有主要地位, 不确定性推理的研究方法不断出现, 如概率推理方法<sup>[2]</sup>, 证据推理方法<sup>[2]</sup>, 模糊推理方法<sup>[3]</sup>等都属于不确定性推理方法。由于推理中的蕴含关系, 实质上是一种包含关系, 不确定性推理方法都可以归结为一种特殊的包含度。同时, 知识获取是从大量案例中寻求某些规则, 而规则的前件与后件实质上也是一种包含关系<sup>[4]</sup>, 因此可以用包含度理论研究不确定性规则的获取。两个规则是谐调的, 是指两个规则的前件的相似度不超过两个规则后件的相似度, 因此可以用

\* 本文1996年4月4日收到。

包含度建立两个规则之间的协调度，解决矛盾规则的排除问题。包含度理论与模糊集理论一起，将“对象”与“关系”不确定化，成为研究不确定性的重要工具，提供了研究复杂系统的重要方法。

## § 2 包含度的概念

两个集合的包含度是指一个集合包含于另外一个集合的程度。

设  $X$  是一个论域， $A$  和  $B$  是  $X$  中的两个子集合，集合  $A$  包含于集合  $B$  的程度  $D(B/A)$  称为包含度，如果它满足以下四条公理：

公理 1  $0 \leq D(B/A) \leq 1$ ；

公理 2  $A \subset B$  时， $D(B/A) = 1$ ；

公理 3  $A \subset B \subset C$  时， $D(A/C) \leq D(A/B)$ ；

公理 4  $A \subset B$  时，对于任意  $C$  有  $D(A/C) \leq D(B/C)$ 。

公理 1 是对包含度的规范化，包含度在  $[0, 1]$  中取值。公理 2 表示包含度与经典包含的协调性，经典包含关系是包含度为 1 的特殊情况。公理 3 与公理 4 是包含度的单调性。精略地说，一个较小的集合比较容易包含在一个较大的集合中。在使用包含度的公理中，有时可仅利用公理 3 或公理 4 之一即可。

例 1 设  $X$  是有限集合， $N(A)$  表示  $A$  中元素个数，对于  $A, B \subset X$ ，记

$$D(B/A) = \frac{N(A \cap B)}{N(A)}$$

则  $D(B/A)$  为  $A$  关于  $B$  的包含度。例如当  $A = \{x_1, \dots, x_6\}$ ,  $B = \{x_5, x_6, \dots, x_{10}\}$ ，则  $D(B/A) = 1/3$ 。

设  $X$  是一个论域， $A$  和  $B$  是  $X$  上的模糊集，若对于任意  $x \in X$ ,  $A(x) \leq B(x)$ ，称  $A$  包含于  $B$ ，记作  $A \subset B$ 。这样包含度也可以定义在  $X$  的模糊集上，即有包含度  $D(B/A)$ 。对经典集合  $A \subset B$  有  $D(B/A) = 1$ 。但对于模糊集， $A \subset B$  时  $D(B/A) = 1$  未必成立。

例 2 设  $P$  是  $X$  上的概率测度，模糊集  $A$  的模糊概率为

$$P(A) = \sum_{i=1}^l A(x_i)P(x_i)$$

于是

$$D(B/A) = P(A^c \cup B)$$

是包含度。对于经典集合  $A$  和  $B$ ,  $A \subset B$  时,  $A^c \cup B = X$ , 于是  $D(B/A) = P((A^c \cup B)) = P(X) = 1$ 。对于模糊集  $A$  和  $B$ ,  $A \subset B$  时  $A^c \cup B \neq X$ , 于是未必有  $D(B/A) = 1$ 。

由包含度的概念出发，我们可以在  $[0, 1]$  上定义“包含度”，它实质上是一种“小于度”。对于  $[0, 1]$  中两个数  $a$  和  $b$ ，称  $D(b/a)$  为包含度，如果它满足以下公理：

公理 1  $0 \leq D(b/a) \leq 1$ ；

公理 2  $a \leq b$  时， $D(b/a) = 1$ ；

公理 3  $a < b < c$  时， $D(a/c) \leq D(a/b)$ ；

公理 4  $a < b$  时，对于任意  $c$  有  $D(a/c) \leq D(b/c)$ 。

例 3 设  $a, b$  是  $[0, 1]$  中的两个数，则

$$D(b/a) = (1 - a + b) \wedge 1$$

是包含度。

在 $[0,1]$ 上定义的包含度，使不确定性带来的误差不会造成相反的结果。比如甲的真实高度为1.73米，乙的真实高度为1.74米，测量结果可能甲为1.74米，乙为1.73米，这样就会得到“甲比乙高”的相反结论。如果计算包含度有 $D(1.73/1.74) = (1 - 1.74/2 + 1.73/2) \wedge 1 = 0.995$ ，即甲小于乙的程度为0.995。

不管是经典集合的包含关系，模糊集合的包含关系，还是 $[0,1]$ 上的“ $\leq$ ”关系，都是一种半序关系。因此包含度可以定义在任何半序集上，将半序关系赋予一种度量。

### §3 包含度理论与概率推理

包含度理论概括了已有的各种不确定性推理方法。

在不确定性推理中，最早出现的是概率推理，利用条件概率 $P(B/A)$ 进行推理，容易证明

$$D(B/A) = P(B/A)P(A \cap B)/P(A)$$

是一种包含度。由于在条件变量比较多的情况下，条件概率的数量大大增加，这在实际中是难于获得的，因此出现了概率推理的两种变形，一种是主观 Bayes 方法，一种是 MYCIN 不确定因子方法。主观 Bayes 方法是给出了条件成立时假设成立的强度 $LS$ ，和条件不成立假设成立的强度 $LN$ ，用两个规则强度计算条件概率<sup>[4]</sup>，由于

$$D_1(h/e) = P(\bar{e} \vee h) = P(e = 0 \text{ 或 } h = 1)$$

$$D_2(h/e) = P(\bar{e}/\bar{h}) = P(e = 0, h = 0)/P(h = 0)$$

也是包含度，则得到主观 Bayes 方法的另外两种新的方法。

**定理 1** 设 $h$ 为假设， $e$ 为证据，则

$$D_1(h/e) = 1 - \frac{(1 - LN)P(\bar{h})}{LS - LN} \quad (1)$$

$$D_1(h/\bar{e}) = 1 - \frac{(LS - 1)P(\bar{h})}{LS - LN} \quad (2)$$

**证明** 由主观 Bayes 方法，有

$$P(h/\bar{e}) = \frac{LS \cdot P(h)}{(LS - 1)P(h) + 1} \quad (3)$$

$$P(h/e) = \frac{LN \cdot P(h)}{(LN - 1)P(h) + 1} \quad (4)$$

利用全概率公式

$$P(h) = P(h/\bar{e})P(\bar{e}) + P(h/e)P(e)$$

即得

$$P(e) = \frac{(1 - LN)[(LS - 1)P(h) + 1]}{(LS - LN)} \quad (5)$$

$$P(\bar{e}) = \frac{(LS - 1)[(LN - 1)P(h) + 1]}{(LS - LN)} \quad (6)$$

将(3)和(5)代入 $D_1(h/e) = P(\bar{e} \vee h) = 1 - P(e \wedge \bar{h}) = 1 - (1 - P(h/e)) \cdot P(e)$

$$D_1(h/e) = P(\bar{e} \vee h) = 1 - P(e \wedge \bar{h}) = 1 - (1 - P(h/e)) \cdot P(e)$$

即得(1), (2)类似可证。

**定理2** 设  $h$  为假设,  $e$  为证据, 则有  
 $D_2(h/e) = (LS - 1)/(LS + LN)$   
 $D_2(h/e) = (1 - LN)/(LS + LN)$

**证明** 与定理1类似。

概率推理的另外一种方法是 MYCIN 不确定因子方法<sup>[3]</sup>。MYCIN 不确定因子是利用给定条件下信任增加的程度

$$MB(h/e) = \begin{cases} \frac{P(h/e) \vee P(h)}{P(h)}, & P(h) \neq 1 \\ 1, & P(h) = 1, \end{cases}$$

和怀疑增加的程度

$$MD(h/e) = \begin{cases} \frac{P(h) - P(h/e) \wedge P(h)}{P(h)}, & P(h) \neq 0 \\ 1, & P(h) = 0. \end{cases}$$

给出不确定因子:

$$CF(h/e) = MB(h/e) - MD(h/e),$$

但可以证明  $MB(h/e)$  是包含度 (不满足公理4),  $1 - MD(h/e)$  是包含度 (不满足公理4)。于是

$$D(h/e) = (MB(h/e) + 1 - MD(h/e))/2 = (CF(h/e) + 1)/2$$

是包含度。 $CF(h/e)$  是在  $[-1, 1]$  中取值,  $D(h/e)$  是将  $CF(h/e)$  规范化, 因此不确定因子实质上是一种包含度。

## § 4 包含度理论与模糊推理

设  $T$  是  $[0, 1]$  上的三角模, 即满足交换律、结合律、单调性和  $T(a, 1) = a$  ( $0 \leq a \leq 1$ ) 的二元函数, 则

$$D(b/a) = ab, b = \sup\{c; T(a, c) \leq b\}$$

是  $[0, 1]$  上的包含度。于是在模糊推理中的蕴含关系即是包含度

$$R(x, y) = D(B(y)/A(x)) = A(x) \alpha_T B(y)$$

如果我们用  $R(x, y) = A(x) \wedge B(y)$  作为蕴含关系, 可以用包含度建立合成规则

$$(A \circ R)(y) = \sup D(R(x, y)/A(x)).$$

假定 II 为可能度<sup>[4]</sup>, 即满足

$$\Pi(A \cup B) = \Pi(A) \vee \Pi(B)$$

则

$$D_1(B/A) = \Pi(A^c \cup B)$$

$$D_2(B/A) = \sup\{t; \Pi(A \cap B) = T(t, \Pi(A))\}$$

是包含度。对于  $D_2$  来讲, 若  $A \subset B$ , 则  $\Pi(A \cap B) = \Pi(A)$ , 由  $\Pi(A) = T(t, \Pi(A))$  及三角模性质, 知  $t=1$ , 于是  $A \subset B$  时  $D_2(B/A)=1$ 。但是对于  $D_1$  来讲, 仅对经典集合  $A \subset B$  时, 有  $D_1(B/A)=1$ 。如果  $A$  与  $B$  是正则模糊集<sup>[1]</sup>, 则公理2对于  $D_1$  中取模糊集也成立。

同样, 假定 N 是必然度<sup>[4]</sup>, 即满足

$$N(A \cap B) = N(A) \wedge N(B)$$

则  $N(B/A) = \inf\{N(A^c(x) \vee B(x)) : x \in X\}$

$$N(B/A) = \inf\{N(A^c(x) \vee B(x)) : x \in X\}$$

是包含度。但公理 2 也仅对经典集合成立。

**定理 3** 用  $\mathcal{F}^*(x)$  表示  $X$  上是正则模糊集的全体, 则  $\mathcal{F}^*(x)$

$$M(B/A) = \begin{cases} \Pi(B/A), & \text{若 } N(B/A) > 0.5 \\ (N(B/A) + 0.5) \cdot \Pi(B/A), & \text{若 } N(B/A) \leq 0.5 \end{cases}$$

是  $\mathcal{F}^*(X)$  上的包含度。

**证明** 公理 1, 2, 4 易证。只需证公理 3 成立。现设  $A \subseteq B \subseteq C$ , 则有,

$$\Pi(A/C) = \Pi(A/B) = 1$$

$$N(A/C) \leq N(A/B)$$

若  $N(A/C) > 0.5$ , 则  $N(A/B) > 0.5$ , 于是

$$M(A/C) = M(A/B) = \Pi(A/B) = 1$$

若  $N(A/C) \leq 0.5$ , 则  $N(A/C) \leq 0.5$ , 于是

$$M(A/C) = (N(A/C) + 0.5) \cdot \Pi(A/C)$$

$$\leq (N(A/C) + 0.5) \cdot \Pi(A/B) = M(A/B)$$

若  $N(A/C) \leq 0.5$ ,  $N(A/B) > 0.5$ ,  $M(A/B) = 1$ , 显然有

$$M(A/C) \leq M(A/B)$$

于是  $M$  为包含度。

## § 5 包含度理论与证据推理

Dempster 和 Shafer 提出证据理论以后, 形成了一种不确定推理方法, 即证据推理。证据理论中主要是利用 mass 函数<sup>[2]</sup>, 它是由人的经验给出的一种评价。如果给出关系数据库, 即可用包含度理论确定 mass 函数。

设  $X = \{x_1, x_2, \dots, x_n\}$  为对象集,  $\Theta = \{\theta_1, \dots, \theta_m\}$  为属性集。 $V$  为  $X \otimes \Theta$  上的模糊关系。 $V_j(x)$  表示  $x$  具有属性  $\theta_j$  的隶属度。记

$$\sigma(x) = \sum V_j(x)/\theta_j$$

$$\delta(x) = \sum V_j(x)/\theta_j$$

对于任何  $x \in X$ ,  $\sigma(x)$ ,  $\delta(x)$  是  $\Theta$  上的模糊集。对于  $\Theta$  上的模糊集  $Q$ , 记

$$\sigma^{-1}(Q) = \{x; \sigma(x) = Q\}$$

$$\delta^{-1}(Q) = \{x; \delta(x) = Q\}$$

则有下面的

**定理 4** 设  $P$  为  $X$  上的概率分布, 则

$$m_1(Q) = P(\delta^{-1}(Q)) \quad (7)$$

$$m_2(Q) = P(\sigma^{-1}(Q)) \quad (8)$$

为  $\Theta$  的全体模糊集上的 mass 函数, 且由(7)和(8)确定的信任测度与似然测度分别为

$$B_1(Q) = P\{g(Q^c)\}, L_1(Q) = P\{g(Q)\}$$

$$B_2(Q) = P\{K(Q^c)\}, L_2(Q) = P\{K(Q)\}$$

其中

$$g(Q) = \{x; Q \subseteq \sigma(x)\} \quad (9)$$

$$K(Q) = \{x; Q \subseteq \delta(x)\} \quad (10)$$

证明 首先易证  $Q_1 \neq Q_2$  时

$$\delta^{-1}(Q_1) \cap \delta^{-1}(Q_2) = \emptyset$$

$$\sigma^{-1}(Q_1) \cap \sigma^{-1}(Q_2) = \emptyset$$

对模糊关系  $V$  作出假设,  $\forall x \in X, V_j(x) (j \leq M)$  不全为 0, 也不全为 1;  $j \leq M, V_j(x) (x \in X)$  不全为 0, 也不全为 1。这时易知  $\delta^{-1}(\emptyset) = \emptyset, \sigma^{-1}(\emptyset) = \emptyset, \bigcup \delta^{-1}(\xi) = X, \bigcup \sigma^{-1}(\xi) = X$ , 于是  $\delta^{-1}(\xi)$  及  $\sigma^{-1}(\xi)$  为  $X$  的划分, 于是(7)和(8)式确定了 mass 函数。由信任度与似然度和 mass 函数关系即证  $B_i$  与  $L_i$  成立。

(9)与(10)中使用了包含关系, 我们可以用包含度来代替包含关系。设  $D$  为  $\Theta$  上模糊集的包含度, 记

$$\delta_*(Q) = D(Q/\delta(x))$$

$$\delta^*(Q) = 1 - D(Q/\delta(x))$$

$$\sigma_*(Q) = D(Q/\sigma(x))$$

$$\sigma^*(Q) = 1 - D(Q/\sigma(x))$$

取

$$B'_1(Q) = P\{\delta_*(Q)\}, L'_1(Q) = P(\delta^*(Q))$$

$$B'_2(Q) = P\{\sigma_*(Q)\}, L'_2(Q) = P(\sigma^*(Q))$$

则有

$$B_2 \leq B'_1, L'_1 \leq L_1$$

$$B_2 \leq B'_2, L'_2 \leq L_2$$

于是用包含度得到了更精确的区间估计  $[B'_1, L'_1]$  和  $[B'_2, L'_2]$ 。

## § 6 包含度理论与信息推理

胡国定先生引进了信息量[5], 采用补集的概率。一般来说, 一个概念的属性越多信息越大, 但对象越多时信息量越少, 因此用  $I(p) = P(\bar{A})$  表示命题  $p$  的信息, 其中  $A$  为  $p$  的外延对象集合。容易证明

$$D(q/p) = P(A \cap \bar{B})/P(\bar{B})$$

为包含度, 其中  $A$  和  $B$  分别为概念  $p$  和  $q$  的外延对象集合。

若  $D(q/p) = 1$ , 则  $P(\bar{B}) = P(\bar{A} \cap \bar{B})$ , 于是  $P(\bar{B} \setminus \bar{A}) = 0$ , 记为  $\bar{A} \subset \bar{B}$ , 即  $q$  的信息覆盖  $p$  的信息。这时 “ $p \Rightarrow q$ ” 为必然命题。若

$$\Delta P(A, B) = P(\bar{B} \setminus \bar{A}) + P(\bar{A} \setminus \bar{B}) = 0$$

则  $p$  与  $q$  为等价命题, 记为  $p \equiv q$ 。

若  $D(q/p) < 1$  称为或然推理, 记为 “ $p \rightarrow q$ ”;  $D(p/q)$  表示 “ $p \rightarrow q$ ” 可信的程度。

由  $D(q/p) = 1$  确定的必然命题 “ $p \Rightarrow q$ ” 有必然命题的全部性质。由  $D(q/p) < 1$  确定的或然命题有新的性质。若  $D(q/p) > 0$  时, 称  $p$  真时  $q$  更可信。则有下面的

**定理 5** 对于命题  $p$  和  $q$  有以下结论:

(1) 若  $p \Rightarrow q$ ,  $q$  真, 则  $p$  更可信;

(2) 若  $\bar{p} \Rightarrow q$ ,  $q$  假, 则  $\bar{p}$  更可信;

(3) 若  $p \Rightarrow q$ ,  $p$  假, 则  $q$  更可信;

(4) 若  $p \Rightarrow q$ ,  $q$  假, 则  $p$  更可信。

证明 以(1)为例证明。由  $p \Rightarrow q$ , 则

$$D(q/p) = P(\bar{A} \cap \bar{B})/P(\bar{B})$$

于是  $P(\bar{B}) = P(\bar{A} \cap \bar{B}) > 0$ , 则  $P(\bar{A}) > 0$ , 从而

$$D(p/q) = P(\bar{A} \cap \bar{B})/P(\bar{A}) > 0$$

即  $q$  真时  $p$  更可信。其它情形类似可证。

## § 7 专家系统中知识获取

专家要获取知识, 首先要有案例。案例有两部分组成, 一部分是条件属性的不同状态, 一部分是假设的不同结果。案例是可以重复、不一致的, 甚至是矛盾的。它是多个专家的经验, 一般数量较大。知识获取是在大量的案例中提炼出几条规则, 构成知识库中的知识。

我们用案例中假设的状态对案例分类; 用  $B_j$  表示案例中假设为第  $j$  种决策的案例全体,  $q$  表示假设的不同决策数, 则  $\mathcal{B} = \{B_j; j \leq q\}$  将所有案例进行分类。同样, 我们也可以用案例中条件属性(或部分属性)将案例进行分类, 用  $A_i$  表示案例属性的第  $i$  个状态的案例全体;  $p$  表示条件属性所有可能的状态, 则  $\mathcal{A} = \{A_i; i \leq p\}$  将所有案例进行了分类。若  $A_i \subset B_j$ , 得到规则  $A_i \Rightarrow B_j$ , 即

若条件属性为第  $i$  个状态, 则假设为第  $j$  个决策

但是对于某些  $A_i$ , 可能会对所有  $B_j$ ,  $A_i \subset B_j$  不成立, 这时无法得到确定的规则。若  $D(B_j/A_i)$  为包含度, 取  $B_{j_0} \in \mathcal{B}$ , 使

$$\alpha_i = \max_{\leq q} D(B_j/A_i) = D(B_{j_0}/A_i)$$

那么我们得到或然规则  $A_i \rightarrow B_{j_0}(\alpha_i)$ , 即

若条件属性为第  $i$  个状态, 则假设为第  $j_0$  种决策  
这条规则的可信度为  $\alpha_i$ 。

一般来说, 条件属性中的条件变量是比较的。开始时可用一个条件变量进行分类, 逐步试探, 再增加条件变量, 一直到所有规则强度  $\alpha_i$  接近于 1 为止。

在上述试探过程中, 对于某一步可计算

$$\alpha = \min_{\leq p} \max_{\leq q} D(B_j/A_i)$$

$\alpha$  为所有规则的最小可信度。可以证明:

定理 6 设  $\mathcal{A} = \{A_i; i \leq p\}$ ,  $\mathcal{B} = \{B_j; j \leq q\}$  为所有案例的两个分类, 则

$$D(\mathcal{B}/\mathcal{A}) = \min_{\leq p} \max_{\leq q} D(B_j/A_i)$$

为所有分类上的包含度。

由此可见, 用包含度理论从案例中提取知识是一个简单而成功的方法。这种方法还可以用在模式识别中。

## § 8 规则的谐调度与矛盾规则的排除

包含度理论的另外一个成功的应用是建立不同规则之间的谐调度，解决矛盾规则的排除问题。

知识库中的知识可以是用 § 7 中方法得到的，也可以是专家的经验。不管是那种情况，都难于保证知识库中的知识是协调的。知识库中的知识必须要有一定的谐调性，否则会影响知识库的使用效果。

为了建立规则之间的谐调度，首先我们建立相似度。设  $S(B/A)$  为模糊集的包含度，则

$$S_1(A, B) = D(B/A) \wedge D(A/B)$$

$$S_2(A, B) = D(A \cap B/A \cup B)$$

是相似度，且具有以下性质：

(1)  $0 \leq S_i(A, B) \leq 1$ ；

(2)  $S_i(A, B) = S_i(B, A)$ ；

(3)  $A \subset B \subset C$  时  $S_i(A, C) \leq S_i(A, B) \wedge S_i(B, C)$ .

一般来说，用同一种包含度得到的相似度  $S_1$  和  $S_2$  是不相同的，但对于定理 3 中包含度得到的相信度  $S_1$  和  $S_2$  是相同的。

设 “ $A_1 \rightarrow B_1$ ” 和 “ $A_2 \rightarrow B_2$ ” 是两条模糊规则，用  $S(A_1, A_2)$  表示两条规则前件的相似度， $S(B_1, B_2)$  表示两条规则后件的相似度， $D$  为  $[0, 1]$  上的包含度，两条模糊规则的谐调度为

$$C_{12} = D(S(B_1, B_2)/S(A_1, A_2))$$

$C_{12}=1$  表示两条模糊规则是模糊谐调的。对于一组模糊规则 “ $A_i \rightarrow B_i$ ” ( $i \leq n$ )，可以求任何两条模糊规则的谐调度而构成谐调度矩阵：

$$C = (C_{ij}; i, j \leq n)$$

从谐调度矩阵  $C$  中找出最小的数排除相应的行和列，一直到谐调度矩阵元素都不小于某一个强度为止，剩余的规则是相对谐调的规则集。

谐调度矩阵  $C$  是满足  $C_{ii}=1$  ( $i \leq n$ ) 和对称的矩阵，我们也可以用模糊聚类法将规则集聚为若干类，这样每一类里的知识是相对谐调的。

模糊规则的谐调度还刻画了模糊关系方程有公共解的性质。

定理 7 设 “ $A_1 \rightarrow B_1$ ” 和 “ $A_2 \rightarrow B_2$ ” 为两条模糊规则，若它们有公共解  $R$  满足

$$A_1 \circ R = B_1, \quad A_2 \circ R = B_2$$

则  $C_{12}=1$ ，其中谐调度中的包含度用例 3 中定义的包含度，相似度用

$$S(A_1, A_2) = \min_x \frac{A_1(x) \wedge A_2(x)}{A_1(x) \vee A_2(x)}$$

“集合”和“关系”是客观世界的两个重要特征，也是研究客观世界的两个重要概念。包含度理论给出了不确定关系的定理描述，将确定关系的研究推进到不确定关系的研究。它对于人工智能、专家系统、模式识别、系统分析、管理决策、经济规划都有着重要意义。

## 参 考 文 献

- [1] Zadeh, L. A. Fuzzy Sets. *Information and Control*, No. 8, 1965, pp 338-353
- [2] Shafer, G. A. *Mathematical Theory of Evidence*. Princeton University Press, Princeton, New Jersey, 1976
- [3] Kruse, R. Schwecke, E. and Heinsohn, J. *Uncertainty and Vagueness in Knowledge Based Systems*. Springer-Verlag, Berlin, Heidelberg, 1991
- [4] Mantaras, R. L. D. *Approximate Reasoning Models*. Ellis-Horwood Limited, 1990
- [5] Hu, Guo-Ding. *Information and Probable Inference*, Proceedings of the International Workshop on Automated Reasoning, Beijing, China. 1992., pp84-107
- [6] Grzymbala-Busse, J. W. *Managing Uncertainty in Expert Systems*. Kluwer Academic Publisher, 1991
- [7] Neapolitan, R. E. *Probabilistic Reasoning in Expert Systems*. A Wiley-Interscience Publication, 1990
- [8] Dubois, D. and Prade, H. *Possibility Theory*. Plenum Press, 1988
- [9] 张文修, 梁怡. 不确定性推理原理. 西安: 西安交通大学出版社, 1996

## Inclusion Degree Theory

张文修(西安交通大学, 陕西西安 710049), 梁怡(香港中文大学, 香港)

W. X. Zhang (Z. B. Xu) (Xian Jiaotong University, Xian, 710049), Y. Liang (The Chinese University of Hong Kong)

### Abstract

不确定推理是人工智能领域的一个重要研究方向, 对此领域的贡献, 在于提出了一种新的包含度理论。该理论系统地发展了不确定性推理的统一方法, 并解决了专家系统的许多问题。

**Keywords:** Inclusion Degree; Uncertainty Reasoning; Knowledge Acquisition