

基于一般二元关系下的粗糙 Vague 集^{*})

邱卫根

(广东工业大学计算机学院 广州 510090)

摘要 本文研究了一般关系下 Vague 集合的近似问题,建立了一般关系下粗糙 Vague 近似的框架。在分析经典的粗集理论、模糊集理论、Vague 集理论三者关系的基础上,提出了一般关系下粗糙 Vague 集的概念,并定义了粗糙 Vague 近似算子,讨论了粗糙 Vague 的性质。本文的结果对进一步开展粗糙集 Vague 集的研究具有一定的意义。

关键词 粗糙集,模糊集,Vague 集,粗糙 Vague 集

Rough Vague Sets Based on General Binary Relation

QIU Wei-Gen

(Computer Faculty of GuangDong University of Technology, Guangzhou 510090)

Abstract In this paper, the upper and low rough approximation operators based on general binary relation of Vague set are studied. Firstly, the relationship between Rough sets, Fuzzy sets and Vague sets is analyzed, which are all important tools for AI and KDD. Some results for the rough Vague sets are presented, which are some meaningful to farther study of the rough Vague sets.

Keywords Rough sets, Fuzzy sets, Vague sets, Rough vague sets

1 引言

粗集理论提供了一种有效表示和处理知识的强有力的工具,特别是在完备信息系统的处理上取得巨大成功,得到了广泛的研究和应用^[1]。由于实际应用领域的需要,Palawk 粗集理论被自然地扩展到了模糊领域,模糊集合和粗糙集合自然地融合在一起^[2,3]。Vague 集理论建立在模糊集理论的基础上^[4],进一步拓宽了模糊集对事物表达的范围,用一个真隶属函数 t_A (表示对象隶属集合 A 的支持度)和假隶属函数 f_A (表示对象隶属集合 A 的反对程度)来描述隶属函数 μ_A 的界。Vague 集目前在国内外模糊控制、决策、故障诊断等领域得到广泛的关注^[5~7],对模糊信息处理、知识表达等起到了重要的作用。

本文研究了一般关系下 Vague 集合的近似问题,建立了一般关系下粗糙 Vague 近似的框架。首先分析了经典的粗集理论、模糊集理论、Vague 集理论三者之间的关系,提出了一般关系下粗糙 Vague 集的概念,并用构造性方法定义了粗糙 Vague 近似算子,讨论了粗糙 Vague 的性质。粗糙 Vague 集的研究对于处理一定形式的数据或知识信息具有工具性使用价值,进一步开展粗糙集与 Vague 集融合的研究具有现实的意义。

2 Vague 集的引入

$U = \{x_1, x_2, \dots, x_n\}$ 是有限集合, $n = |U|$, 称为论域。 R 是定义在 U 上的一个等价关系(或称为不可区分关系), U/R 表示其相应的分类,记 $[x]_R$ 为 x 的等价类。子集合 A 称为概念,概念 A 的上近似集合 $\bar{R}A$ 、下近似集合 RA 定义如下:

$\bar{R}A = \{x | x \in U, [x]_R \cap A \neq \emptyset\}$, $RA = \{x | x \in U, [x]_R \subseteq A\}$

$\bar{R}A$ 是可能属于集合 A 的所有对象的集合,表示可能的支持度;而 RA 是确定属于集合 A 的所有对象的集,表示已经确定的支持度。

设 A 是 U 上的一个语言表示的模糊集合, $A = \{(x, \mu_A(x)) | x \in U, \mu_A(x) \in [0, 1]\}$, $\mu_A(x) \in [0, 1]$ 是一个隶属函数,表示论域 U 中对象 x 属于模糊集合 A 的程度。 $\mu_A(x)$ 的值越大,表明该对象 x 属于模糊集合 A 的程度越高,或者实例 x 对语言概念 A 的支持程度越高。

由于在模糊集合中,隶属函数 $\mu_A(x)$ 既被用来表示对象 x 对模糊集合 A 的支持度,又包含了对象 x 反对模糊概念 A 的证据,这使 $\mu_A(x)$ 又可能陷入了传统的二值逻辑的范畴。Vague 集理论的提出恰好避免了这个陷阱。

Vague 集理论的主要特征是同时给出了支持和反对的证据,用真隶属函数 t_A 和假隶属函数 f_A 同时描述隶属函数 μ_A 的界,即 $t_A(x) \leq \mu_A(x) \leq 1 - f_A(x)$ 。这样对象 x 对模糊概念 A 的隶属程度不再是一个值,而是一个区间,这样表达了一个多值逻辑。例如 $[t_A(x), 1 - f_A(x)] = [0.4, 0.8]$, 则 $t_A(x) = 0.4, 1 - f_A(x) = 0.8, f_A(x) = 0.2$ 。在投票模型中,可以解释为在 10 个人中,有 4 人投赞成票,2 个人投反对票,4 人弃权。

定义 1 设 U 是有限集论域空间, Vague 集 A 用一个真隶属函数 t_A 和一个假隶属函数 f_A 表示,任意 $x \in U, t_A(x) \in [0, 1]$ 表示对象 x 属于集合 A 的隶属度下界, $f_A(x) \in [0, 1]$ 表示对象 x 不属于 A 的下界, $t_A(x)$ 和 $f_A(x)$ 将 U 中对象 x 与概念 A 的关系表示为 $[t_A(x), 1 - f_A(x)] \subseteq [0, 1]$, 其中 $t_A(x) + f_A(x) \leq 1$ 。

在 Vague 集的定义中,值 $1 - f_A(x) - t_A(x)$ 描述 x 对于概念 A 的不确定性,表明了我们对 x 的认识程度。若 $1 - f_A(x) = t_A(x)$, 则 Vague 集退化为模糊集;若 $1 - f_A(x) = t_A(x) \in \{0, 1\}$, 则 Vague 集退化为经典集合。

^{*})广东省自然科学基金资助课题(994386)。

当 U 为连续空间时, Vague 集 A 可以表示为 $A = \int_U [t_A(x), 1 - f_A(x)]/x dx, x \in U$; 当 U 为离散空间时, Vague 集 A 则表示为 $A = \sum_{x_i \in U} [t_A(x_i), 1 - f_A(x_i)]/x_i, x_i \in U$.

3 主要结果

定义 2 设 U 是有限论域空间, A, B 是 U 上的 Vague 集, $A = \sum_{x_i \in U} [t_A(x_i), 1 - f_A(x_i)]/x_i, B = \sum_{x_i \in U} [t_B(x_i), 1 - f_B(x_i)]/x_i$, 集合 A 和集合 B 的并集 C 和交集 D 分别表示如下:

$$C = A \cup B = \sum_{x_i \in U} [t_C(x_i), 1 - f_C(x_i)]/x_i; D = A \cap B = \sum_{x_i \in U} [t_D(x_i), 1 - f_D(x_i)]/x_i.$$

其中 $t_C(x_i) = \max\{t_A(x_i), t_B(x_i)\}, 1 - f_C(x_i) = \max\{1 - f_A(x_i), 1 - f_B(x_i)\}; t_D(x_i) = \min\{t_A(x_i), t_B(x_i)\}, 1 - f_D(x_i) = \min\{1 - f_A(x_i), 1 - f_B(x_i)\}, \forall x_i \in U$.

例 1: $A = [0.2, 0.4]/x_1 + [0.6, 0.8]/x_2 + [0.3, 0.7]/x_3 + [0.5, 0.9]/x_4 + [0.8, 1.0]/x_5,$

$B = [0.3, 0.5]/x_1 + [0.2, 0.5]/x_2 + [0.3, 0.6]/x_3 + [0.8, 0.9]/x_4 + [1.0, 1.0]/x_5,$

则 $A \cup B = [0.3, 0.5]/x_1 + [0.6, 0.8]/x_2 + [0.3, 0.7]/x_3 + [0.8, 0.9]/x_4 + [1.0, 1.0]/x_5,$

$A \cap B = [0.2, 0.4]/x_1 + [0.2, 0.5]/x_2 + [0.3, 0.6]/x_3 + [0.5, 0.9]/x_4 + [0.8, 1.0]/x_5.$

定义 3 设 U 是有限论域, $R = R(x, y)_{n \times n}$ 是 U 上关系, $n = |U|, \forall x, y \in U, R(x, y) \in [0, 1], A = \sum_{x_i \in U} [t_A(x_i), 1 - f_A(x_i)]/x_i$ 是 U 上的 Vague 集, 定义 A 集相对于关系 R 的上近似集 \bar{A}_R 、下近似集 \underline{A}_R 如下:

$$\bar{A}_R = \sum_{x_i \in U} [t_{\bar{A}_R}(x_i), 1 - f_{\bar{A}_R}(x_i)]/x_i,$$

$$\underline{A}_R = \sum_{x_i \in U} [t_{\underline{A}_R}(x_i), 1 - f_{\underline{A}_R}(x_i)]/x_i$$

其中: $t_{\bar{A}_R}(x) = \max_{y \in U} \{\min(R(x, y), t_A(y))\}, 1 - f_{\bar{A}_R}(x) = \max_{y \in U} \{\min(R(x, y), 1 - f_A(y))\}, t_{\underline{A}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), t_A(y))\}, 1 - f_{\underline{A}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), 1 - f_A(y))\}.$

引理 1 如果 R 是 U 上经典的等价关系, 则

1) $t_{\bar{A}_R}(x) = \max\{t_A(y) | y \in [x]_R\}, f_{\bar{A}_R}(x) = \min\{f_A(y) | y \in [x]_R\},$

2) $t_{\underline{A}_R}(x) = \min\{t_A(y) | y \in [x]_R\}, f_{\underline{A}_R}(x) = \max\{f_A(y) | y \in [x]_R\}.$

证明: 若 R 是经典的等价关系, 则 $\forall y \in [x]_R, R(x, y) = 1, \max(1 - R(x, y), t_A(y)) = t_A(y); \forall y \notin [x]_R, R(x, y) = 0, \max(1 - R(x, y), t_A(y)) = 1;$

$$1) t_{\bar{A}_R}(x) = \max_{y \in U} \{\min(R(x, y), t_A(y))\}$$

$$= \max_{y \in [x]_R} \{\min(R(x, y), t_A(y))\} \max_{y \notin [x]_R} \{\min(R(x, y), t_A(y))\}$$

$$= \max_{y \in [x]_R} \{t_A(y), 0\} = \max\{t_A(y) | y \in [x]_R\}$$

$$1 - f_{\bar{A}_R}(x) = \max_{y \in U} \{\min(R(x, y), 1 - f_A(y))\}$$

$$= \max_{y \in [x]_R} \{\min(R(x, y), 1 - f_A(y))\}, \max_{y \notin [x]_R} \{\min(R(x, y), 1 - f_A(y))\}$$

$$(x, y), 1 - f_A(y))\} = \max_{y \in [x]_R} \{1 - f_A(y), 0\} = \max\{1 - f_A(y) | y \in [x]_R\}$$

$$[x]_R = 1 - \min\{f_A(y) | y \in [x]_R\}$$

$$\text{即 } f_{\bar{A}_R}(x) = \min\{f_A(y) | y \in [x]_R\}.$$

$$2) t_{\underline{A}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), t_A(y))\}$$

$$= \min_{y \in [x]_R} \{\max(1 - R(x, y), t_A(y))\}, \min_{y \notin [x]_R} \{\max(1 - R(x, y), t_A(y))\}$$

$$= \min_{y \in [x]_R} \{t_A(y)\}, 1 = \min\{t_A(y) | y \in [x]_R\}$$

$$1 - f_{\underline{A}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), 1 - f_A(y))\}$$

$$= \min_{y \in [x]_R} \{\max(1 - R(x, y), 1 - f_A(y))\}, \min_{y \notin [x]_R} \{\max(1 - R(x, y), 1 - f_A(y))\}$$

$$= \min_{y \in [x]_R} \{1 - f_A(y)\}, 1 = \min\{1 - f_A(y) | y \in [x]_R\}$$

$$= 1 - \max\{f_A(y) | y \in [x]_R\}$$

即 $f_{\bar{A}_R}(x) = \max\{f_A(y) | y \in [x]_R\}.$

定理 1 设 U 是有限论域, $R = R(x, y)_{n \times n}$ 是 U 上关系, A, B 是 U 上的 Vague 集, $A = \sum_{x_i \in U} [t_A(x_i), 1 - f_A(x_i)]/x_i, B = \sum_{x_i \in U} [t_B(x_i), 1 - f_B(x_i)]/x_i, A \subseteq B$, 则

$$1) \underline{A}_R \subseteq \underline{B}_R, \bar{A}_R \subseteq \bar{B}_R,$$

$$2) \underline{A} \cap \underline{B}_R = \underline{A}_R \cap \underline{B}_R, \bar{A} \cup \bar{B}_R = \bar{A}_R \cup \bar{B}_R$$

$$3) \underline{A}_R \cup \underline{B}_R \subseteq \underline{A} \cup \underline{B}_R, \bar{A} \cap \bar{B}_R \subseteq \bar{A}_R \cap \bar{B}_R$$

证明: 因为 $A \subseteq B$, 则对 $\forall x \in U, t_A(x) \leq t_B(x), 1 - f_A(x) \leq 1 - f_B(x).$

$$1) t_{\underline{A}_R}(x) = \min_{y \in U} \{\max(R(x, y), t_A(y))\} \leq \max_{y \in U} \{\min(R(x, y), t_B(y))\} = t_{\underline{B}_R}(x)$$

$$1 - f_{\underline{A}_R}(x) = \max_{y \in U} \{\min(R(x, y), 1 - f_A(y))\} \leq \max_{y \in U} \{\min(R(x, y), 1 - f_B(y))\} = 1 - f_{\underline{B}_R}(x)$$

$$t_{\bar{A}_R}(x) = \max_{y \in U} \{\min(1 - R(x, y), t_A(y))\} \leq \max_{y \in U} \{\min(1 - R(x, y), t_B(y))\} = t_{\bar{B}_R}(x)$$

$$1 - f_{\bar{A}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), 1 - f_A(y))\} \leq \min_{y \in U} \{\max(1 - R(x, y), 1 - f_B(y))\} = 1 - f_{\bar{B}_R}(x)$$

所以 $\underline{A}_R \subseteq \underline{B}_R, \bar{A}_R \subseteq \bar{B}_R.$

$$2) t_{\underline{A} \cap \underline{B}_R}(x) = \min_{y \in U} \{\max(1 - R(x, y), t_{A \cap B}(y))\}$$

$$= \min_{y \in U} \{\max(1 - R(x, y), \min\{t_A(y), t_B(y)\})\}$$

$$= \min_{y \in U} \{\min(\max(1 - R(x, y), t_A(y)), \max(1 - R(x, y), t_B(y)))\}$$

$$= \min(\min_{y \in U} \{\max(1 - R(x, y), t_A(y))\}, \min_{y \in U} \{\max(1 - R(x, y), t_B(y))\})$$

$$= \min(t_{\underline{A}_R}(x), t_{\underline{B}_R}(x))$$

$$\min(1 - f_{\underline{A}_R}(x), 1 - f_{\underline{B}_R}(x))$$

$$= \min\{\min_{y \in U} \{\max(1 - R(x, y), 1 - f_A(y))\}, \min_{y \in U} \{\max(1 - R(x, y), 1 - f_B(y))\}\}$$

$$= \min\{\min(\max(1 - R(x, y), 1 - f_A(y)), \max(1 - R(x, y), 1 - f_B(y)))\}$$

$$= \min_{y \in U} \{\max(1 - R(x, y), \min(1 - f_A(y), 1 - f_B(y)))\}$$

$$= 1 - f_{\underline{A} \cap \underline{B}_R}(x)$$

即 $\underline{A} \cap \underline{B}_R = \underline{A}_R \cap \underline{B}_R.$

$$t_{\bar{A} \cup \bar{B}_R}(x) = \max_{y \in U} \{\min(R(x, y), t_{A \cup B}(y))\}$$

$$= \max_{y \in U} \{\min(R(x, y), \max\{t_A(y), t_B(y)\})\}$$

$$= \max_{y \in U} \{\max(\min(R(x, y), t_A(y)), \min(R(x, y), t_B(y)))\}$$

$$= \max(\max_{y \in U} \{\min(R(x, y), t_A(y))\}, \max_{y \in U} \{\min(R(x, y), t_B(y))\})$$

$$= \max(t_{\bar{A}_R}(x), t_{\bar{B}_R}(x))$$

“缩放法”在高端和低端同时有效。作者的理解是，“扩大法”在此也是一种模糊化方法，它扩大和精确化事物的细节，却模糊化了事物的整体，即缩小和模糊化了训练样本和新的模式之间的整体差别，同样促进了网络泛化能力的提高。

“缩小法”适用于 PNN 和 RBFN，“扩大法”适用于 LVQ 网络和 BPNN。不同的方法适用于不同的对象，不同的对象需要用不同的思想方法去认识它们。“荧屏效应”和下面给出的“模糊模缩”算子，可进一步揭示“缩放法”和“扩大法”的作用机制。

模糊模缩算子 对于向量 p 、模 m 和缩放因子 α ，定义 p 的 α 模糊模缩运算 $F \text{ mod } S$ 为：

$$F \text{ mod } S(\alpha p) = \begin{cases} f(\alpha p), & \alpha \leq 1 \\ g((\alpha - m)p), & \alpha > 1 \end{cases} \quad (9)$$

其中， $m \in I$ (整数集)， f 和 g 是实函数，二者可以相同，例如，有时可取 $f(\alpha p) = \alpha p$ ， $g((\alpha - m)p) = (\alpha - m)p$ ，等等，但一般来说，二者是不同的。

可以认为，在 BPNN 和 LVQ 网络的内部，存在着函数 f 和 g ，它们都是隐函数而不是显函数。在对 BPNN 和 LVQ 网络运用 SMA 时，网络内部固有的模糊模缩运算使得在 α 取值的某些区间和某些点上，训练样本和测试样本之间的语义距离减小了，从而减小了误识率，提高了网络的泛化能力。

结束语 本文从模糊理论角度提出了一种改进 NN 泛化能力的新方法和新算法，它们是通过缩小或放大样本数据，从

而缩小或模糊化训练样本和测试样本之间的差别来实现的。大量实验例证了其有效性，并对其原理进行了初步的分析和讨论。实验和分析表明，SMA 方法和 α 算法简单可靠，效果明显，具有一定的理论基础，可用以改进和提高许多神经网络的泛化能力。当然，NN 是个大家族，尽管我们做了大量实验，且有很多实验结果在文中无法一一给出，但毕竟不能穷尽。因此，SMA 方法及 α 算法应用价值和理论价值的进一步提升还依赖于更多的研究和实践。

参考文献

- 1 Sarle W S. Stopped training and other remedies for overfitting. In: Proc. of the 27th Symposium on the Interface, 1995
- 2 Hinton G E. Connectionist learning procedures. Artificial Intelligence, 1989, 40: 185~234
- 3 武妍, 王守觉. 一种通过反馈提高神经网络学习性能的新算法. 计算机研究与发展, 2004, 41(9): 488~492
- 4 Ishibuchi H, Nii M. Fuzzification of input vector for improving the generalization ability of neural networks. In: The Int'l Joint Conf. on Neural Networks, Anchorage, Alaska, 1998
- 5 Hansen L K, Salamon P. Neural Network Ensembles. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1990, 12(10): 993~1001
- 6 Specht D F. Probabilistic neural networks. Neural Networks, 1990, 3(1): 109~118
- 7 Jang J S R, Sun C T, Mizutani E. Neuro-Fuzzy and Soft Computing. Upper Saddle River, NJ: Prentice-Hall Inc, Simon & Schuster/A Viacom Company, 1997
- 8 冯乃勤. 模糊概念的模糊度研究. 模式识别与人工智能, 2002, 15(3): 290~294

(上接第 192 页)

$$\begin{aligned} & \max\{1 - f_{\bar{A}_R}(x), 1 - f_{\bar{B}_R}(x)\} \\ & = \max\{\max\{\min(R(x, y), 1 - f_A(y)), \max\{\min(R(x, y), 1 - f_B(y))\}\}\} \\ & = \max\{\max\{\min(R(x, y), 1 - f_A(y)), \min(R(x, y), 1 - f_B(y))\}\} \\ & = \max\{\min(1 - R(x, y), \max\{1 - f_A(y), 1 - f_B(y)\})\} \\ & = 1 - f_{\overline{A \cup B}_R}(x) \\ & \text{即 } \overline{A \cup B}_R = \bar{A}_R \cup \bar{B}_R. \\ & 3) t_{\Delta_R \cup B_R}(x) = \max\{t_{\Delta_R}(x), t_{B_R}(x)\} \\ & = \max\{\min\{\max\{1 - R(x, y), t_A(y)\}\}, \min\{\max\{1 - R(x, y), t_B(y)\}\}\} \\ & \leq \min\{\max\{\max\{1 - R(x, y), t_A(y)\}, \max\{1 - R(x, y), t_B(y)\}\}\} \\ & = \min\{\max\{1 - R(x, y), \max\{t_A(y), t_B(y)\}\} = t_{\Delta \cup B_R}(x) \\ & 1 - f_{\Delta_R \cup B_R}(x) = \max\{1 - f_{\Delta_R}(x), 1 - f_{B_R}(x)\} \\ & = \max\{\min\{\max\{1 - R(x, y), 1 - f_A(y)\}\}, \min\{\max\{1 - R(x, y), 1 - f_B(y)\}\}\} \\ & \leq \min\{\max\{\max\{1 - R(x, y), 1 - f_A(y)\}, \max\{1 - R(x, y), 1 - f_B(y)\}\}\} \\ & = \min\{\max\{1 - R(x, y), \max\{1 - f_A(y), 1 - f_B(y)\}\}\} \\ & = \min\{\max\{1 - R(x, y), 1 - f_{A \cup B}(y)\}\} = 1 - f_{\Delta \cup B_R}(x) \\ & \text{即 } \bar{A}_R \cup \bar{B}_R \subseteq \overline{A \cup B}_R. \\ & t_{\bar{A} \cap \bar{B}_R}(x) = \max\{\min\{R(x, y), t_{A \cap B}(y)\}\} \\ & = \max\{\min\{R(x, y), \min\{t_A(x), t_B(x)\}\}\} \\ & = \max\{\min\{\min\{R(x, y), t_A(x)\}\}, \min\{R(x, y), t_B(x)\}\} \\ & \leq \min\{\max\{\min\{R(x, y), t_A(x)\}\}, \max\{\min\{R(x, y), t_B(x)\}\}\} \end{aligned}$$

$$\begin{aligned} & (x))\} \\ & = \min\{t_{\bar{A}_R}(x), t_{\bar{B}_R}(x)\} = t_{\bar{A}_R \cap \bar{B}_R}(x) \\ & 1 - f_{\bar{A} \cap \bar{B}_R}(x) = \max\{\min\{R(x, y), 1 - f_{A \cap B}(y)\}\} \\ & = \max\{\min\{R(x, y), \min\{1 - f_A(y), 1 - f_B(y)\}\}\} \\ & = \max\{\min\{\min\{R(x, y), 1 - f_A(y)\}, \min\{R(x, y), 1 - f_B(y)\}\}\} \\ & \leq \min\{\max\{\min\{R(x, y), 1 - f_A(y)\}\}, \max\{\min\{R(x, y), 1 - f_B(y)\}\}\} \\ & \leq \min\{1 - f_{\bar{A}_R}(x), 1 - f_{\bar{B}_R}(x)\} = 1 - f_{\bar{A}_R \cap \bar{B}_R}(x) \\ & \text{即 } \bar{A} \cap \bar{B}_R \subseteq \overline{A \cap B}_R. \end{aligned}$$

结论 本文研究了一般关系下 Vague 集合的近似问题，建立了一般关系下粗糙 Vague 近似的框架。首先分析了经典的粗集理论、模糊集理论、Vague 集理论三者之间的关系，提出了一般关系下粗糙 Vague 集的概念，并用构造性方法定义了粗糙 Vague 近似算子，讨论了粗糙 Vague 的性质。粗糙 Vague 集的研究对于处理一定形式的数据或知识信息具有工具性使用价值，进一步开展粗糙集与 Vague 集融合的研究具有现实的意义。

参考文献

- 1 王珏, 苗夺谦, 周育健. 关于 Rough Set 理论与应用的综述. 模式识别与人工智能, 1998, 11: 34~40
- 2 Yao Y Y. A Comparative study of fuzzy sets and rough sets. Journal of Information Sciences, 1998, 109: 227~242
- 3 米据生, 张文修, 徐宗本. 粗糙模糊集的构造与公理化方法. 计算机学报, 2004, 27(3): 197~202
- 4 闫德勤, 迟志先. 粗糙集与 Vague 集. 计算机科学, 2004, 31(8): 133~135
- 5 江莉, 等. Vague 决策表的知识获取. 计算机科学, 2004, 31(8): 111~112
- 6 李凡, 等. 基于 Vague 集的加权多目标模糊决策方法. 计算机科学, 2001, 28(7): 60~62
- 7 符海东, 卢正鼎. 基于 Vague 集的模糊决策方法. 小型微型计算机系统, 2004, 25(9): 1684~1686