

基于粒网络生成规则的文本分类研究^{*}

张 霞^{1,2} 尹怡欣¹ 于海燕^{2,3} 赵海龙¹

(北京科技大学信息工程学院 北京 100083)¹ (河北经贸大学计算机中心 石家庄 050061)²

(北京科技大学经济管理学院 北京 100083)³

摘 要 文本分类是数据挖掘的一种应用,分类器的设计是其中最重要的一个环节。与那些基于统计方法的分类算法比较,给予规则的分类算法在很多情况下更具优越性。提出了一种基于粒运算的方法,通过建立粒网络生成分类规则,从而实现文本分类的方法。本算法通过从最大的粒中提取较小粒,直至产生最小粒的过程建立起一个粒网络,从而产生分类规则,实现文本的分类。

关键词 粒网络,粒运算,规则,文本分类

Research on Text Classification Based on Rule Mining by Granule Network Constructing

ZHANG Xia^{1,2} YIN Yi-xin¹ YU Hai-yan^{2,3} ZHAO Hai-long¹

(School of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China)¹

(Computer Center, Hebei University of Economics and Business, Shijiazhuang 050061, China)²

(School of Economics and Management, University of Science and Technology Beijing, Beijing 100083, China)³

Abstract Text classification is one of the practices of knowledge discovery and designation of the classifier is the most important part. Comparing with the methods based on statistic theory, classification based on rule learning is a better one in some situations. A granular computing approach was proposed to learn classification rules by constructing a granule network. The algorithm is involved in a refining process from the largest granule to the smallest one. By constructing a granule network, text classification rules are learned.

Keywords Granular network, Granular computing, Rule, Text classification

1 引言

知识发现和数据挖掘经常被用来提取人们感兴趣的信息和模式,挖掘隐藏在非结构化文本数据中的信息是知识发现的一个有意义的应用。文本分类是通过对训练文本的机器学习实现对分类器的建模,从而实现文本的分类。

自动文本分类是先提取文本的主要特征,通过对训练文本集进行机器学习建立分类模型,然后用这个分类模型将未知类别的文本归入事先划分的类。这个分类模型就是文本分类器,文本分类器的设计是整个文本分类的关键。

目前,国内外对文本分类器的设计大概是以下几种方法:KNN(K 最小近邻)、SVM(支持向量机)和 Bayes(贝叶斯)。这些方法都是基于统计的方法,具有操作简单、高精度的优点。不过,当类别之间的交叉比较多,语料文本不充分时,这些方法的分类精度就会很差,特别是多层分类时情况更严重。在这种情况下,基于规则的分类方法更有效。

本文将形式概念分析和粒运算结合,提出一种通过建立粒网络生成分类规则的方法进行文本分类。粒运算是一个包含了多理论、方法、技术和工具的用粒(子集)解决问题的伞状的综合系统。利用定义的语言集 L 描述概念的两个方面:内涵和外延。概念的内涵用一个语言公式来表示,概念的外延表示为符合这个公式的一个对象集合,从而构造一个粒。

粒网络的建立是一个自顶向下的粒搜索过程,从最大的粒提取较小粒,直到产生属于同一个预定义类的粒,即最小粒。最小粒就是论域中可定义的合取粒。最小粒的族就形成了一个由可定义合取粒组成的覆盖。粒网络的建立得到分类规则,从而实现文本的分类。

基于此,本文提出一种粒运算的方法来对分类器的设计进行建模,提取分类规则从而实现文本的分类。

2 分类问题的粒运算基础

形式概念的研究中,每个概念都可以理解为两部分:概念的内涵和外延。概念的内涵用一个语言公式来表示,概念的外延表示为符合这个公式的一个对象集。公式表达法让我们在内涵方面学习到了形式概念的逻辑框架,在外延方面学习到了形式概念的理论框架。在知识发现、数据挖掘和分类的粒运算模型中,一个对象集表示为一个信息表。

2.1 粒和概念的表达方法

一个信息表可以表示为下面元组:

$$s = (U, At, L, \langle V_a | a \in At \rangle, \{I_a | a \in At\})$$

这里, U 是有限非空对象集,即论域; At 是有限非空属性集; L 是定义 At 中属性的语言; V_a 是符合 $a \in At$ 的非空集; $I_a: U \rightarrow V_a$ 是一个信息函数。

在语言 L 中,一个原子公式定义为 $a = v$, 此时 $a \in At$ 并

^{*} 基金项目:国家自然科学基金项目(60374032),北京市教委重点学科共建项目基金(00002268)。张 霞 讲师,博士,主要研究领域为人工智能、数据挖掘;尹怡欣 博士,教授,博士生导师,主要研究领域为人工智能、智能管理、人工生命;于海燕 副教授,博士,主要研究领域为数据挖掘、粗糙集、粒计算;赵海龙 主要研究领域为人工智能、模式识别。

且 $v \in V_a$ 。如果 ϕ 和 ψ 是公式,那么 $\neg\phi, \phi \wedge \psi, \phi \vee \psi$ 都是公式。如果 ϕ 是一个公式, \vDash 表示可满足于, $m_s(\phi) = \{x \in U \mid x \vDash \phi\}$ 表示满足公式 ϕ 的对象集合,简称为 $m(\phi)$ 。信息表中一个概念定义为 $(\phi, m(\phi))$, ϕ 是概念 $(\phi, m(\phi))$ 的内涵, $m(\phi)$ 是概念 $(\phi, m(\phi))$ 的外延。

由此,我们引入了粒的表示及运算。对于公式 ϕ ,我们得到一个粒 $m(\phi)$ 。如果 $m(\phi)$ 和 $m(\psi)$ 分别是对应于公式 ϕ 和 ψ 得到的粒,则我们可以得出如下粒运算:

$$\begin{aligned} m(\neg\phi) &= \neg m(\phi) \\ m(\phi) \cap m(\psi) &= m(\phi \wedge \psi) \\ m(\phi) \cup m(\psi) &= m(\phi \vee \psi) \\ m(\phi \rightarrow \psi) &= \neg m(\phi) \cup m(\psi) \end{aligned}$$

如果公式 $a=v$ 是原子公式,则 $m(a=v)$ 称为基本粒,概念 $(a=v, m(a=v))$ 称为基本概念。

2.2 与粒相关的运算

与粒有关的计算有 4 种定量的计算方法。单个粒的度量、一对粒之间关系的度量、一个粒与一个粒族之间关系的度量,还有一对粒族之间关系的度量。

(1)由公式 ϕ 产生的单个粒 $m(\phi)$ 的度量用通用率(Generality)来表示一个粒的相对大小: $G(\phi) = |m(\phi)|/|U|$ 。

(2)给两个公式 ϕ 和 ψ ,通常用置信度或绝对支持度和覆盖率对两个粒 $m(\phi)$ 和 $m(\psi)$ 之间的关系进行度量。

根据 $\phi \Rightarrow \psi$ 条件得到的两个粒间关系的置信度或绝对支持度是:

$$AS(\phi \Rightarrow \psi) = |m(\psi \wedge \phi)|/|m(\phi)| = |m(\psi) \cap m(\phi)|/|m(\phi)|$$

$$CA(\phi \Rightarrow \psi) = |m(\psi \wedge \phi)|/|m(\psi)| = |m(\psi) \cap m(\phi)|/|m(\psi)|$$

(3)由公式集合 $\Psi = \{\psi_1, \dots, \psi_n\}$ 得到一个粒族 $\{m(\psi_1), \dots, m(\psi_n)\}$,则我们得到根据 $\phi \Rightarrow \psi_i$ 产生的分配概率为:

$$P(\Psi | \phi) = (AS(\phi \Rightarrow \psi_1), \dots, AS(\phi \Rightarrow \psi_n))$$

相应地,粒 $m(\phi)$ 与粒族 $\{m(\psi_1), \dots, m(\psi_n)\}$ 间关系的条件熵值:

$$H(\Psi | \phi) = -\sum_{i=1}^n AS(\phi \Rightarrow \psi_i) * \log(AS(\phi \Rightarrow \psi_i))$$

(4)假设另一个由公式 $\Phi = \{\phi_1, \dots, \phi_m\}$ 定义的粒族 $\{m(\phi_1), \dots, m(\phi_m)\}$,两个粒族之间的条件熵值是

$$H(\Psi | \Phi) = -\sum_{j=1}^m \sum_{i=1}^n P(\psi_i \wedge \phi_j) * \log P(\psi_i | \phi_j)$$

2.3 划分和覆盖

划分和覆盖是论域粒化中两个简单又普遍的方法。一个划分由论域无交集的子集合组成,而覆盖包括可能的重叠交集。划分是一种特殊的覆盖。在粒运算中,我们将每个划分或覆盖的元素都看作一个粒,每个粒都可以更深层次分成更小的划分或覆盖。用划分解决分类问题和用覆盖解决分类问题的区别在于划分中一个对象只能用一个规则表示,而覆盖中的一个对象则可以用一个或更多的规则表示。

如果一个划分 π_1 全部包含在另一个划分 π_2 当中,则划分 π_1 是划分 π_2 的细化,表示为 $\pi_1 \leq \pi_2$ 。同样地,如果一个覆盖 τ_1 全部包含在另一个覆盖 τ_2 当中,则覆盖 τ_1 是覆盖 τ_2 的细化,表示为 $\tau_1 \leq \tau_2$ 。

2.4 一致性分类问题

假设一个信息表描述一个对象集合,我们假定有一个唯一的属性 class,每个对象的 class 值都对应唯一的一个预定义的类标签。属性集合表示为 $At = F \cup \{class\}$, F 是用来描

述对象的属性集合。一致性分类问题可以描述为:如果所有 F 中有相同描述的对象都属于同一个类,即如果 $I_F(x) = I_F(y)$,则 $I_{class}(x) = I_{class}(y)$ 。

分类问题,我们关心的是从 F 中发现一个属性子集来产生正确的分类。 π_{class} 表示根据属性 class 得到的划分,可以很容易理解:当且仅当存在一个可定义合取的划分 π ,满足 $\pi \leq \pi_{class}$ 并且 π 可产生一致性分类,则我们可以用划分 π 来产生正确的分类。因此,同样地,我们也可以理解:当且仅当存在一个可定义合取的覆盖 τ ,满足 $\tau \leq \pi_{class}$ 并且 τ 可产生一致性分类,则我们可以用覆盖 τ 来产生正确的分类。

2.5 分类算法

2.5.1 ID3

ID3 是一种典型的自上而下的分类树方法。我们首先选一个属性将论域根据不同的属性值分成若干个划分。如果一个等价类不属于一个预定义的类,我们就用另外一个属性分解这个划分,直到每一个最小的划分都是属于一个预定义的类。通过上述描述的过程,就形成了一个决策树,其中每个节点代表一个属性,每个分枝代表一个属性的值。这种方法很容易理解和实践,它是一种以属性为导向的方法,一次就搜索一个划分。我们期待一种覆盖的方法。

2.5.2 PRISM

PRISM 是 1987 年由 Jadia Cendrowska 提出的,它是一种以属性-值为导向的方法。PRISM 从训练集中直接提取分类规则,下面列出了 PRISM 算法,很容易看出来它是一个基于覆盖的算法。

D) for $i=1$ to n

II) repeat

(1)计算每对属性-值的组合对 class i 的置信度值(confidence)。

(2)选择置信度值最大的那对属性-值,并选择符合这对属性-值的对象。通过这一步,建立了训练集的一个最大的子集。

(3)对选中的子集重复(1)和(2),直到产生的子集中的对象只属于某一类 class i ,所有这些被选中的属性-值的交集建立了一条 class i 的分类规则。

(4)从训练集中去掉覆盖这条规则的对象。

until class i 中的所有对象都被去掉。

2.6 通过粒网络的建立进行分类

将 ID3 和 PRISM 方法进行扩充,提出一个通过建立粒网络的方法导出分类规则。建立粒网络的方法也是基于覆盖的方法。分类问题可以通过自上而下构造粒网络的方法来解决。

在粒网络中,每个节点是论域的一个子集或者一个粒,建立粒网络的过程就是一个从最大的粒提取较小粒,直到产生最小粒的过程。

最大的粒是一个所有对象的集合。原子公式 $a=v$ 定义了基本粒 $m(a=v)$,记为 $bg_{a=v}$,相应的基本概念 $(a=v, m(a=v))$ 记为 $BC_{a=v}$ 。属性 class 定义了粒 $m(class=i)$,记为 $g_{class=i}$ 。首先计算基本粒 $bg_{a=v}$ 和粒族 $\{g_{class=1}, \dots, g_{class=n}\}$ 的条件熵值,即为相应的基本概念 $BC_{a=v}$ 的熵值。选择条件熵值符合阈值的基本粒作为二级粒。从最大的粒引出分枝指向所有二级粒,每个分枝被相应的原子公式标示。在基本概念 $BC_{a=v}$ 中去掉这些被选中二级粒对应的基本概念,得到没有使用的基本概念,记为 $UBC_{a=v}$ 。对每一个二级粒分别重新计算 $UBC_{a=v}$ 的熵值,同样选择熵值符合阈值的原子公式,在二

级粒中提取出符合原子公式的对象集合作为三级粒。连接二级粒和三级粒,分枝分别标示相应原子公式。重复此过程,直到产生的粒中的对象都属于一个预定义的类,即产生最小粒。这样,最小粒就是论域中可定义的合取粒。最小粒的族就形成了一个由可定义合取粒组成的覆盖。

分类时,我们的目的就是要发现分类规则,诸如这种形式: $\varphi \Rightarrow class = i$,这里 φ 是 F 属性集合产生的公式,表示为产生最小粒的过程中原子公式的合取公式。

3 基于粒网络生成规则的文本分类

3.1 文本分类技术

正如我们知道的,文本分类是一个大而复杂的工程,通常包括下面几个步骤:建立训练集和测试集;提取文本特征(关键词);用训练数据通过机器学习方法来设计一个分类器;用测试集数据测试分类器。

特征提取是从文本中提取重要的特征(关键词或主题词)。特征提取有很多典型的方法,如文档频率(Document Frequency)、信息增益(Information Gain)、期望交叉熵(Cross Entropy)等等。这些技术主要作用是实现特征向量的降维以及选择代表性的文本特征。这是一个必需的预处理步骤。

分类方法有很多,主要的有 K 最小近邻法(K Nearest Neighbor)、支持向量机(Support Vector Machines)和贝叶斯法(Bayes)。这些算法都是通过比较训练文本中不同的模板决定文本的类别,是基于统计理论的。在下面情况下分类精确度会大大下降:

(1)当类之间的重叠现象比较严重(两类之间有较多共同的文本特征)时;(2)如果训练文本不是太充分时。这时,基于规则的分类方法会很好地克服基于统计的方法精确度急剧下降的弱点。另外,这些情况下文本特征维数自然会降低,更利于分类精确度的提高。

3.2 训练文本信息表

假设有一个文本训练集如下:

- T1={f3, f4}
- T2={f2, f3, f4, f7, f8, f9}
- T3={f2, f3, f4, f8, f9}
- T4={f2, f3, f4, f7, f8}
- T5={f1, f2, f6, f9, f10}
- T6={f1, f5, f7}
- T7={f1, f5, f6, f7}

我们定义 $FS = \{f1, f2, \dots, f10\}$, FS 是包括所有训练文本的文本特征的属性集。每一个训练文本 T 被看作是一个事务, TS 是训练文本的集合, $T \subseteq TS$ 。此时,属性集 $At = FS \cup \{class\}$ 。

表 1 训练文本信息表

TEXT	f1	f2	f3	f4	f5	f6	f7	f8	f9	f10	class
T1	n	n	y	y	n	n	n	n	n	n	1
T2	n	y	y	y	n	n	y	y	y	n	2
T3	n	y	y	y	n	n	n	y	y	n	2
T4	n	y	y	y	n	n	y	y	n	n	2
T5	y	y	n	n	n	y	n	n	y	y	3
T6	y	n	n	n	y	n	y	n	n	n	4
T7	y	n	n	n	y	y	y	n	n	n	4

导致规则变复杂,难以理解和操作。有两种方法可以避免训练数据的过分拟合。

前缀树:当决策数分枝的数据例过少或者分枝没有意义时,提前停止树的生长。

后缀树:通过在后期修剪分枝,减少决策树的过度膨胀。

我们的实验中,阈值的选择应用了前缀树的剪枝方法。在从粒中提取较小的粒,阈值选择子粒的族形成一个覆盖的最小值,有效地控制了树的宽度,避免了没有意义的分枝增长。

3.3.2 建立粒网络的算法

建立粒网络的算法可以归纳:

I)建立由原子公式得到的基本概念集合:

$$BC(TS) = \{(a=v, m(a=v)) | a \in FS, v \in V_a\}.$$

II)建立没有用过的基本概念集合 $UBC(TS) = BC(TS)$ 。

III)建立粒网络 $GN = (\{TS\}, \Phi)$, 初始状态的粒网络只包含一个节点,即最大粒,并且没有弧。此节点是包含所有 T 的集合。

IV)While GN 中最小的粒不属于同一个类时,

(1)计算每一个没有用过的基本概念的熵值;

(2)计算阈值;

(3)选择熵值达到阈值的基本概念 $C = (a=v, m(a=v))$;

(4)设置 $UBC(TS) = BC(TS) - \{C\}$;

(5)修改粒网络 GN , 加上新节点,即新粒。此粒是在其父粒中提取符合相应原子公式 $a=v$ 的对象集合形成的子粒,连接父粒与子粒,弧上标示 $a=v$ 。

3.3.3 基本概念的量度值

表 2 是基本粒及其条件熵值。熵值的范围在本例中是从 0 到 2。熵值越接近 0,由原子公式定义的粒越适合选择,根据基本概念的量度值,选择其中满足阈值的。有 7 个粒选择作为二级粒。表 2 中黑色加重的基本概念即为粒网络的二级粒。

表 2 基本粒及其条件熵值

原子公式	基本粒	置信度				条件熵值
		Class1	Class2	Class3	Class4	
f1=y	{T5, T6, T7}	0	0	0.3333	0.6667	0.9183
f1=n	{T1, T2, T3, T4}	0.2500	0.7500	0	0	0.8113
f2=y	{T2, T3, T4, T5}	0	0.7500	0.2500	0	0.8113
f2=n	{T1, T6, T7}	0.3333	0	0	0.6667	0.9183
f3=y	{T1, T2, T3, T4}	0.2500	0.7500	0	0	0.8113
f3=n	{T5, T6, T7}	0	0	0.3333	0.6667	0.9183
f4=y	{T1, T2, T3, T4}	0.2500	0.7500	0	0	0.8113
f4=n	{T5, T6, T7}	0	0	0.3333	0.6667	0.9183
f5=y	{T6, T7}	0	0	0	1.0000	0
f5=n	{T1, T2, T3, T4, T5}	0.2000	0.6000	0.2000	0	1.3710
f6=y	{T5, T7}	0	0	0.5000	0.5000	1.0000
f6=n	{T1, T2, T3, T4, T6}	0.2000	0.6000	0	0.2000	1.3710
f7=y	{T2, T4, T6, T7}	0	0.5000	0	0.5000	1.0000
f7=n	{T1, T3, T5}	0.3333	0.3333	0.3333	0	1.5850
f8=y	{T2, T3, T4}	0	1.0000	0	0	0
f8=n	{T1, T5, T6, T7}	0.2500	0	0.2500	0.5000	1.5000
f9=y	{T2, T3, T5}	0	0.6667	0.3333	0	0.9183
f9=n	{T1, T4, T6, T7}	0.2500	0.2500	0	0.5000	1.5000
f10=y	{T5}	0	0	1.0000	0	0
f10=n	{T1, T2, T3, T4, T6, T7}	0.1667	0.5000	0	0.3333	1.4591

3.3.4 文本分类的粒网络建立

图 1 是我们建立的粒网络。因为格式限制,我们画出了

其中的一部分。图中所有的矩形对象表示粒网络建立过程中产生的粒。

3.3.5 分类规则的表示

一个分类规则可以用(,)、=、* (合取)、-(非)、+(析取)等符号表示。每一个文本类都有一个或多个分类规则。例如:

Class1=f3 * (-f8)

Class2=f2 * (-f6)

Class2=f8

Class2=(f2 * (-f6)) + f8




图1 部分粒网络

结束语 通过实验,可以得到如下结论:

(1)当类之间的重叠现象比较严重时,如本实验中的class1与class2,如果按基于统计的方法,通过比较训练文本中不同的模板决定文本的类别,则class2中的文本很大比例就会分到class1中,造成分类精度的下降。而本算法表现出较高的精确率。

(2)目前,对论域粒化产生规则的方法,如id3,c4.5决策树,都只是划分的方法,一个对象只能得到一个规则。而本算法是用覆盖的方法产生规则,一个对象可以得到多于一个的规则,适用于语料文档不充裕时的文本分类。而且,由算法的特性决定,覆盖的方法会产生较短的规则。

(3)文本分类中使用此算法,属性值简化为两项,所以运算步骤被大大缩减,便于实践。

参考文献

- [1] Sebastiani F. Machine learning in automated text categorization. ACM Computing Surveys, 2002, 34(1): 1-47
- [2] Yao Jingtao, YAO Yiyu. A granular computing approach to machine learning // Proc. of the 1st International Conference on Fuzzy Systems and Knowledge Discovery. Singapore, 2002; 732-736
- [3] Yao Yiyu. On modeling data mining with granular computing // Proc. of the 25th Annual International Computer Software and Applications Conference. Chicago, 2001; 638-643
- [4] Yao Yiyu. Granular computing: Basic issues and possible solutions // Proc. of the 5th Joint Conference on Information Sciences. Atlantic, 2000; 186-189
- [5] Zhao Yan, Yao Yiyu. Interactive classification using a granule network // Proc. of the Fourth IEEE International Conference on Cognitive Informatics. Washington, 2005; 250-259

(上接第 147 页)

$$(\hat{y}, \hat{y})(k) = G2((\hat{x}, \hat{x})(k), (\hat{u}, \hat{u})(k), \xi_2(k)) \quad (2.2.2)$$

$$(\hat{p}, \hat{p})(k) = \sum_{i=1}^k P((\hat{y}, \hat{y})(i)) \quad (2.2.3)$$

其中 $(\hat{x}, \hat{x})(k)$ 是 (\hat{S}, \hat{S}) 在时刻 k 的状态变量, $(\hat{u}, \hat{u})(k)$ 是 (\hat{S}, \hat{S}) 的动态输出, $\xi_2(k)$ 是状态方程中的随机干扰, $(\hat{y}, \hat{y})(k)$ 是 (\hat{L}, \hat{L}) 的动态反馈输出, $\xi_1(k)$ 是观察随机误差。 k 表示时刻,只取整数值。假定其中的向量全部为有限维状态变量。 (\hat{p}, \hat{p}) 表示系统自主学习性能指标, $P(i)$ 是一个标量函数,表示时刻 i 时的系统自主学习性能。

根据定义可得如下 3 个命题:

命题 1 ALS 是随机系统(Random System)。

命题 2 ALS 是开放系统(Open System)。

命题 3 ALS 是非线性系统(Nonlinear System)。

证明略。

命题 4 现实世界中的各种问题都可以用学习子空间来描述,并且学习子空间包含所有可能的学习路径。若问题可解,则我们必然能从中找到一条学习路径,且为最优(近似最优)学习路径。

证明:将学习问题映射到对应的学习子空间中,从问题初始状态出发,在学习过程中,做每一步路径划分时,描述出当前状态的所有可能的后裔状态,并根据具体的衡量标准从中找出最佳状态,然后做进一步的划分,直至找到目标状态,这就保证了我们能够找到路径,并且为所需的目标路径。需要注意的是在具体的学习算法中由于考虑到计算时间和存储空

间的问题,在大规模的学习问题中一般不会扩展出所有的状态,但是无论是全局最优还是局部最优,根据学习问题的提示信息一定能找到最优(近似最优)的学习路径。

结束语 自主学习公理体系研究是自主学习理论及应用研究的基础。本文利用动态模糊关系,建立了自主学习子空间的公理体系及相关内容。该公理体系由几条相互独立的非常简洁的表达式构成,进一步深化了动态模糊逻辑和自主学习理论。

参考文献

- [1] 闫友彪,陈元琰. 机器学习的主要策略综述. 计算机应用研究, 2004; 4-13
- [2] 王继成. 基于认知模拟的自适应机器学习算法研究. 软件学报, 2001, 12(8): 1205-1211
- [3] 王国胤. 基于 Rough 集理论的自主式机器学习. 计算机科学, 2004, 31(10): 18-20
- [4] 庞维国. 自主学习. 上海: 华东师范大学出版社, 2003
- [5] 陈凤, 李凡长. 李群机器学习(LML)的学习子空间轨道生成理论及算法初探. 苏州大学学报: 自然科学版, 2007, 23(1): 61-66
- [6] Li Fan-zhang. Dynamic Fuzzy Logic and Its Applications. Nova Science Publishers, Sep. 2006
- [7] Wang Jing, Li Fan-zhang. Autonomic Learning Model and Algorithm Based on DFL // 2007 IEEE International Conference on Granular Computing. Silicon Valley, U. S. A
- [8] 刘贵龙. 模糊近似空间上的粗糙模糊集的公理系统. 计算机学报, 2004, 27(9): 1187-1191
- [9] 刘贵龙. Pawlak 粗糙集的公理系统. 系统工程与电子技术, 2006, 28(11): 1752-1755