

# 嵌入代价敏感的极限学习机相异性集成的基因表达数据分类

安春霖 陆慧娟 魏莎莎 杨小兵

(中国计量学院信息工程学院 杭州 310018)

**摘要** 极限学习机的相异性集成算法(Dissimilarity Based Ensemble of Extreme Learning Machine, D-ELM)在基因表达数据分类中能够得到较稳定的分类效果,然而这种分类算法是基于分类精度的,当所给样本的误分类代价不相等时,不能直接实现代价敏感分类过程中的最小平均误分类代价的要求。通过在分类过程中引入概率估计以及误分类代价和拒识代价重新构造分类结果,提出了基于相异性集成极限学习机的代价敏感算法(CS-D-ELM)。该算法被运用到基因表达数据集上,得到了较好的分类效果。

**关键词** 极限学习机,相异性集成,代价敏感,基因表达数据,分类

**中图分类号** TP181 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.12.046

## Dissimilarity Based Ensemble of Extreme Learning Machine with Cost-sensitive for Gene Expression Data Classification

AN Chun-lin LU Hui-juan WEI Sha-sha YANG Xiao-bing

(College of Information Engineering, China Jiliang University, Hangzhou 310018, China)

**Abstract** Dissimilarity based ensemble of Extreme Learning Machine (D-ELM) gets stable classification results on gene expression data classification. While this algorithm is based on the classification accuracy, it cannot meet the requirement to get the minimum misclassification of cost-sensitive classification, when the misclassification costs are not equal. This paper used probability estimate and misclassification cost to reconstruct the classification results. Then we proposed the algorithm of Cost-sensitive Dissimilarity based ensemble of Extreme Learning Machine (CS-D-ELM). This algorithm is applied on the data of gene expression and the experiment demonstrates that it can get better result.

**Keywords** Extreme learning machine, Dissimilarity based ensemble, Cost-sensitive, Gene expression data, Classification

## 1 引言

分类问题广泛存在于机器学习和数据挖掘领域,一直是国内外学者研究的热点,其理论和应用研究已取得丰硕的成果<sup>[1,2]</sup>。目前比较常用的分类方法包括支持向量机、贝叶斯决策、神经网络以及它们的改进算法等。极限学习机<sup>[3-6]</sup>(Extreme Learning Machine, ELM)是最近发展起来的一种快速的机器学习算法,它具有良好的泛化能力和极快的学习速度。然而单个极限学习机的学习性能具有不稳定性。为了进一步提高极限学习机的性能,极限学习机的集成算法也开始迅速地发展。

Lan<sup>[7]</sup>提出了一种在线连续极限学习机集成算法(EOS-ELM),得到了更稳定的性能和更高的分类精度;Tian<sup>[8,9]</sup>分别采用 bagging 集成模式和修正的 AdaBoost. RT 对极限学习机进行集成;Cao<sup>[10]</sup>在 2012 年提出的多数投票极限学习机(V-ELM)得到了广泛的应用;Lu<sup>[11]</sup>等人在 V-ELM 的基础上通过对极限学习机进行选择性别除,进一步提高了个体极限

学习机的差异度,最终提出了相异性极限学习机集成算法(D-ELM)。

然而集成算法中,需要计算样本属于所给类别的概率,然后按照概率判断样本的类标号。但是,如果出现所求概率中最大的两个或多个概率相等或相近的情况,这时给样本标定一个类标号,则判错的概率是非常大的。因此,为了进一步提高 D-ELM 的分类性能,将代价敏感引入到相异性集成中。Foggia<sup>[12]</sup>根据贝叶斯决策规则,提出了一种能够解决多专家系统误分类概率和拒识率的方法,实验证明这种方法相对其他算法是最优的。2006 年,Zheng<sup>[13]</sup>等人将代价敏感因素引入到支持向量机中,进一步降低了分类代价。2010 年,Zou<sup>[14]</sup>等人将误分类代价和拒识代价同时引入到 SVM,进一步改进了代价敏感分类算法的性能。2011 年,Fu<sup>[15]</sup>等人提出了多分类问题代价敏感 AdaBoost 算法,解决了多分类代价敏感分类在转换成二分类代价敏感分类问题时存在的代价合并问题,使得分类结果偏向错分代价较小的类。2012 年,Shi<sup>[16]</sup>等人提出的组合代价敏感支持向量机,解决了传统代

到稿日期:2013-06-25 返修日期:2013-08-16 本文受国家自然科学基金(61272315, 60842009),浙江省自然科学基金(Y1110342),浙江省科技厅国际合作项目(2012C24030)资助。

安春霖(1988-),女,硕士生,CCF 会员,主要研究领域为机器学习、数据挖掘,E-mail:anchunlin0809@126.com;陆慧娟(1962-),女,博士,教授,CCF 杰出会员,主要研究领域为模式识别、生物信息学和物联网等,E-mail:hjlu@cjl.u.edu.cn(通信作者);魏莎莎(1989-),女,硕士生,CCF 会员,主要研究领域为机器学习、数据挖掘;杨小兵(1976-),男,博士,副教授,主要研究领域为模式识别和数据挖掘。

价敏感支持向量机在分类精度上的不可控问题,并将其成功地应用在个人信用分类上。同年,Wan<sup>[17]</sup>等人提出了代价敏感的半监督 Laplacian 支持向量机,但算法在大规模数据集下的求解效率不高。

为了充分利用 D-ELM 分类精度高、性能稳定的优势,提高对不平衡样本的分类性能,本文将误分类代价引入到 D-ELM 中,以降低 D-ELM 在分类过程中造成的平均误分类代价,称这类 D-ELM 为代价敏感相异性集成极限学习机(Cost-sensitive Dissimilarity based of Extreme Learning Machine, CS-D-ELM)。CS-D-ELM 以平均误分类代价最小为目标,而不是追求误分类概率最小,通过提高误分类代价较高的小类别样本的分类精度来实现分类代价最小的目标。在几个常用的基因表达数据集上对 CS-D-ELM 进行验证,并将所得结果与 D-ELM、CS-ELM 及 CS-SVM 进行对比。实验结果表明:CS-D-ELM 能够更好地降低平均误分类代价,提高分类可靠性,尤其是当样本分布不均衡的时候,效果更明显。

## 2 嵌入代价敏感的相异性集成极限学习机

CS-D-ELM 在 D-ELM 中嵌入误分类代价和拒识代价,然后最小化条件风险。

$$\arg \min R(i|x) = \arg \min_j P(j|x) \cdot C(i,j) \quad (1)$$

其中, $R(i|x)$ 是将样本  $x$  分为第  $i$  类的条件风险, $P(j|x)$ 为该样本属于第  $j$  类的概率, $C(i,j)$ 表示将一个  $j$  类样本误判断为第  $i$  的风险。这里, $i,j \in \{c_1, c_2, \dots, c_m\}$ , $m$  是分类的类别数。

### 2.1 极限学习机相异性集成算法(D-ELM)

极限学习机的相异性集成算法是由 Lu<sup>[8]</sup>等人提出的一种多数投票极限学习机的改进算法。基于输出不一致测度对个体极限学习机进行相异性度量,根据相异性剔除理论对极限学习机进行剔除。假设有  $N$  个极限学习机和  $M$  个训练样本。如果第  $i$  个和第  $j$  个极限学习机对第  $k$  个样本的判别结果  $f_{ik}$  和  $f_{jk}$  相同,则标记  $Dif(f_{ik}, f_{jk}) = 0 (i=1, 2, \dots, N; j=1, 2, \dots, N; k=1, 2, \dots, M)$ ; 否则标记  $Dif(f_{ik}, f_{jk}) = 1$ ,用  $Div_{i,j} = \sum_{k=1}^M Dif(f_{ik}, f_{jk})$  表示第  $i$  个极限学习机与第  $j$  个极限学习机的相异性,可得到一个输出不一致性矩阵:

$$Div = \begin{bmatrix} Div_{1,1} & \dots & Div_{1,j} & \dots & Div_{1,N} \\ \vdots & & \vdots & & \vdots \\ Div_{i,1} & \dots & Div_{i,j} & \dots & Div_{i,N} \\ \vdots & & \vdots & & \vdots \\ Div_{N,1} & \dots & Div_{N,j} & \dots & Div_{N,N} \end{bmatrix} \quad (2)$$

显然,  $Div$  是对角线为 0 的对称矩阵。

用  $\eta_i$  表示第  $i$  个极限学习机与其它所有极限学习机的相异性,其中:

$$\eta_i = \sum_{j=1}^N Div_{i,j} \quad (3)$$

计算分类器的平均分类精度  $\bar{p}$ , 当  $0 < \bar{p} \leq 0.5$  时,剔除  $\eta$  较小的极限学习机; 当  $0.5 < \bar{p} < 1$  时,剔除  $\eta$  较大的极限学习机。将剩余的极限学习机进行多数投票集成。

### 2.2 嵌入代价敏感的 D-ELM

假设已知代价矩阵  $C$  为某一固定的矩阵,依据式(1)进

行 CSC 学习,需要估计样本  $x$  属于  $j \in \{c_1, c_2, \dots, c_m\}$  类的概率  $P(j|x)$ 。用所给的数据训练  $N$  个相互独立的 ELM,根据相异性剔除理论对这  $N$  个 ELM 进行剔除,对剩余的  $K$  个 ELM 在训练的过程中都使用相同的隐藏层节点数和激活函数,且每个独立的 ELM 输入层权重和隐藏层偏置都是随机产生且不相关的。这时对于每一个测试样本  $tx$ ,这  $K$  个独立的 ELM 可以预测出  $K$  个独立的分类结果。用一个初始空向量  $(W_{k,tx}(c_1), W_{k,tx}(c_2), \dots, W_{k,tx}(c_m))$  ( $m$  是类别数)来存放这  $K$  个 ELM 对  $tx$  的分类结果。如对于第  $l \in [1, \dots, K]$  个 ELM 分类器,如果  $tx$  的分类结果为  $i, i \in \{c_1, c_2, \dots, c_m\}$ ,那么便进行下面的操作:

$$W_{K,tx}(i) = W_{K,tx}(i) + 1 \quad (4)$$

当所有的  $K$  个 ELM 都运行之后就可以得到一个最终的向量  $W_{K,tx}$ ,这时分类结果的每一类都可以得到一个概率:

$$P(i|tx) = \frac{W_{K,tx}(i)}{K}, i \in \{c_1, c_2, \dots, c_m\} \quad (5)$$

通过 D-ELM 计算出测试样本  $tx$  的条件概率之后,如果  $tx$  被正确分类,且被分为第  $s$  类,那么它属于  $s$  类的概率便大于它的可能类别中其他所有的类,即存在一个不等式:

$$P(s|tx) \geq \max\{P(i|tx)\}_{i \in \{c_1, c_2, \dots, c_m\}} \quad (6)$$

以二分类为例,就可以得到每个测试样本  $tx$  属于正类和负类的概率  $P(p|tx) = \frac{W_{K,tx}(p)}{K}$  和  $P(n|tx) = \frac{W_{K,tx}(n)}{K}$ 。

## 3 算法分析与描述

### 3.1 算法分析

对每个测试样本  $tx$ ,仅仅知道样本的概率  $P(j|tx)$  ( $j \in \{c_1, c_2, \dots, c_m\}$ ) 是不够的,当代价不相等时,即使式(6)成立,也不能判定  $x$  是否属于  $s$  类。因此,本文将非对称误分类代价和拒识代价嵌入到 D-ELM 中,并将嵌入误分类代价和拒识代价的相异性集成极限学习机命名为 CS-D-ELM。

用 2.2 节中的 D-ELM 方法对 ELM 进行相异性集成,计算出  $tx$  属于每一类的概率  $P(j|tx)$ ; 设定代价矩阵  $C$ ,根据式(1)计算其属于某一类  $i$  的代价,并求出它在代价最小的时候的类别:

$$\bar{t}y = \arg \min_i \{R(i|tx)\} = \arg \min_j \{P(j|x) \cdot C(i,j)\} \quad (7)$$

即根据最小化平均误分类代价的原则重新计算测试样本的类标号,记  $\bar{t}y$  为样本的真实类标,它集成了测试样本的误分类代价信息。则嵌入误分类代价之后的分类结果为:

$$\begin{aligned} \overline{TY} &= \begin{bmatrix} \bar{t}y_1 \\ \vdots \\ \bar{t}y_N \end{bmatrix} = \begin{bmatrix} \arg \min_i \{R(i|tx_1)\} \\ \vdots \\ \arg \min_i \{R(i|tx_N)\} \end{bmatrix} \\ &= \begin{bmatrix} \arg \min_j \{P(j|tx_1)\} \cdot C(i,j) \\ \vdots \\ \arg \min_j \{P(j|tx_N)\} \cdot C(i,j) \end{bmatrix} \end{aligned} \quad (8)$$

其中,  $P(j|tx) = \frac{R_{k,tx}(j)}{K}$ ,  $j \in \{c_1, \dots, c_m\}$  为 2.2 节中通过 D-ELM 计算出来的概率。

### 3.2 算法描述

CS-D-ELM 算法步骤:

- 1) 对  $N$  个极限学习机设置初始值;
- 2) 随机产生第  $i$  个 ELM 的输入层参数  $(a_j^i, b_j^i)$ ,  $j = (1, \dots, L)$  ( $L$  为隐层节点个数);
- 3) 计算第  $i$  个 ELM 的隐藏层输出矩阵;
- 4) 计算第  $i$  个 ELM 的输出权重  $\beta^i$ ,  $\beta^i = (H^k)^+ T$ ,  $T$  是目标输出矩阵;
- 5) 对  $N$  个 ELM 采用相异性剔除, 设剔除后的 ELM 有  $K$  个;
- 6) 针对测试样本, 利用剔除后得到的分类器预测  $tx$  的类别, 假设类别为  $j$ ,  $j \in \{c_1, c_2, \dots, c_m\}$ , 则  $W_{K,tx}(j) = W_{K,tx}(j) + 1$ ;
- 7) 计算出测试集属于每一类的概率  $P(j|tx) = \frac{W_{K,tx}(j)}{K}$ ;
- 8) 利用式(8)计算出真实的类标号;
- 9) 结束。

### 4 嵌入拒识的 CS-D-ELM

分类可靠性较低的样本更容易被误分类。为了降低误分类的高代价, 在 CS-D-ELM 的基础上进一步嵌入“拒识选项”, 从而不对分类可靠性低的样本进行自动分类。拒识代价包括以下 3 种情况:

- 1) 被拒识的样本需要其它的进一步分析过程处理所需要的代价;
- 2) 由于拒识决策一个样本而造成的某种损失;
- 3) 以上两种情况都包含。

拒识代价的定义: 假如有一个给定的相当小的正数  $\delta$  (拒识阈), 对于任意的测试样本  $tx$ , 如果有下式成立:

$$R(s|tx) < \max\{R(i|tx)\}_{i \in [c_1, \dots, c_m]_{i \neq s}} \quad (9)$$

$$f(tx) = \min\{R(i|tx)\}_{i \in [c_1, \dots, c_m]_{i \neq s}} - R(s|tx) \quad (10)$$

则当  $f(tx) \geq \delta$  时, 将测试样本分为第  $s$  类; 当  $f(tx) < \delta$  时, 则对样本进行拒识处理。

对于嵌入误分类代价和拒识代价的二元分类问题, 已知给定测试样本  $TX = \{(tx_1, ty_1), \dots, (tx_i, ty_i), \dots, (tx_{\tilde{N}}, ty_{\tilde{N}})\}$  (其中,  $tx_i \in R^n, ty_i \in \{n, p\}, i = 1, \dots, \tilde{N}$ ) 和代价矩阵  $C = \{C(p, n), C(n, p), C(0, n), C(0, p)\}$  (其中,  $C(p, n), C(n, p)$  为误分类代价;  $C(0, n), C(0, p)$  为拒识代价)。根据 2.2 节, 并结合拒识阈  $\delta$  计算概率  $P(0|x)$  (被拒识的概率)、 $P(n|x)$ 、 $P(p|x)$ , 再通过计算最小平均误分类代价来对测试样本进行判定, 即

$$ty = \arg \min_i \{R(i|tx)\} = \arg \min_j \sum_j P(i|x) C(j, i)$$

$i, j \in \{0, n, p\}$ , 这里的拒识阈  $\delta$  是依样本而定的。

## 5 实验与结果分析

### 5.1 实验数据集

实验数据描述: 本文内容针对糖尿病 (Diabetes)、心脏病 (Heart Disease) 和白血病 (Leukemia) 数据集进行分析, 其中 Diabetes 和 Heart 是二分类数据集, Leukemia 是多分类数据集。具体数据集如表 1 所列。

表 1 数据集

数据集	样本总数	特征数	类分布	
			类名	样本数
Diabetes	768	8	relapse	46
			non-relapse	51
Heart	270	13	Negative	150
			Positive	120
Leukemia	72	7129	ALL	24
			MLL	20
			AML	28

### 5.2 CS-D-ELM 的实验结果

根据文献[10]设置数据集的代价矩阵都为  $C(1, -1) = 1, C(-1, 1) = 5$ 。并且在每个数据集上重复实验 30 次, 取这 30 次实验的平均值作为实验结果。每次实验都随机选择一定数量的样本组成训练集, 剩下的样本为测试集。

图 1—图 3 中 D-ELM 和 CS-D-ELM 分别表示用 D-ELM 和 CS-D-ELM 分类得到的平均误分类代价。由图 1—图 3 可以看出, 基于 CS-D-ELM 的平均误分类代价低于基于 D-ELM 的平均误分类代价, 并且随着训练样本数的增加, 两种平均误分类代价都有降低的趋势。




图 1 Diabetes 数据集上的平均测试误分类代价




图 2 Heart 数据集上的平均测试误分类代价




图 3 Leukemia 数据集上的平均测试误分类代价

为了进一步验证 CS-D-ELM 的有效性, 将 CS-D-ELM 与代价敏感极限学习机 (CS-ELM) 和比较成熟的代价敏感支持向量机 (CS-SVM)<sup>[17]</sup> 做对比。实验结果如图 4—图 6 所示。




图 4 Diabetes 数据集上的对比实验




图5 Heart数据集上的对比实验




图6 Leukemia数据集上的对比实验

图4—图6中CS-ELM和CS-SVM分别表示用CS-ELM和CS-SVM分类得到的平均误分类代价。从图中可以看出,CS-D-ELM的平均误分类代价要明显低于CS-SVM及CS-ELM。

### 5.3 嵌入拒识的CS-D-ELM的实验结果

将拒识决策引入CS-D-ELM中,一个重要的过程是确定拒识阈。以Heart数据集为例,在代价矩阵不变的前提下,将拒识代价设置为 $C(0,1)=C(1,0)=0.2$ ,随机选择300个样本作为训练样本集,剩余的为测试样本集,独立重复实验30次求平均值。

从图7中可以看到,当拒识阈 $\delta$ 取值为0.04时可以得到最小的平均误分类代价,将 $\delta=0.04$ 代入CS-D-ELM中重新计算,可以得到如图8所示的结果。由图可知,嵌入拒识代

后可以明显降低平均误分类代价。D-ELM算法因为是在ELM的基础上增加了筛选异质性较大的极限学习机的工作,所以在时间性能上略差,但是在对时间要求不是太高的前提下,通过以上实验可以得出结论:在样本误分类代价不相等且存在拒识决策时,嵌入拒识的CS-D-ELM能够更加有效地降低平均误分类代价。




图7 阈值与平均误分类代价之间的关系




图8 嵌入代价敏感因素效果对比图

为了进一步验证CS-D-ELM在基因表达数据上的普遍适用性,接下来在4个真实数据集上将D-ELM、CS-D-ELM及嵌入拒识的CS-D-ELM进行比较。记正类和负类的分类精度分别为NC和PC,在每个数据集上,取30次实验的平均值作为实验结果。3种算法的NC值、PC值、G-means值和平均误分类代价如表2所列。

表2 D-ELM,CS-D-ELM和嵌入拒识的CS-D-ELM的实验结果

数据集	NC值			PC值			G-means值			平均误分类代价		
	D-ELM	CS-D-ELM	拒识CS-D-ELM	D-ELM	CS-D-ELM	拒识CS-D-ELM	D-ELM	CS-D-ELM	拒识CS-D-ELM	D-ELM	CS-D-ELM	拒识CS-D-ELM
Leukemia	0.3815	0.4714	0.5874	0.9561	0.8626	0.8215	0.6416	0.6508	0.6714	0.4271	0.3522	0.2543
Colon	0.4132	0.5127	0.6322	0.9722	0.9152	0.8464	0.6852	0.7203	0.7313	0.3814	0.2232	0.2123
Mushrooms	0.4325	0.5423	0.6929	1.0000	0.9605	0.9313	0.7125	0.7877	0.7922	0.1102	0.0755	0.0411
Protein	0.3237	0.4621	0.5433	0.9433	0.8956	0.7751	0.5333	0.7122	0.7328	0.4843	0.3812	0.2043

从表2可以看出,CS-D-ELM算法和嵌入拒识的CS-D-ELM算法的G-means值都得到了提高,并且嵌入拒识的CS-D-ELM效果更好;CS-D-ELM在所有的数据集上的平均误分类代价都比D-ELM小,说明CS-D-ELM能够有效地减小在分类过程中产生的误分类代价,且嵌入拒识的CS-D-ELM在所有的数据集上的平均误分类代价都比标准的CS-D-ELM还要低。因此,可以得出结论:在样本误分类代价不相等且存在拒识决策时,嵌入拒识的CS-D-ELM能够更加有效地降低平均误分类代价。

**结束语** 传统的分类算法都是基于分类精度的,当误分类代价不相等时,不能实现代价敏感分类过程中的最小平均误分类代价的要求。本文通过在分类过程中引入概率估计以及误分类代价来重新构造分类结果,提出了基于D-ELM的代价敏感算法CS-D-ELM。在上述算法基础上,嵌入拒识代

价,进一步减小了平均误分类代价,使得不平衡数据的分类更加可靠。

### 参考文献

- [1] Han J, Kamber M. Data mining: concepts and techniques[M]. San Francisco CA, Morgan Kaufmann, 2001: 29-31
- [2] 陆慧娟. 基于基因表达数据的肿瘤分类算法研究[D]. 徐州: 中国矿业大学, 2012
- [3] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006(70): 489-501
- [4] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: a new learning scheme of feedforward neural networks[C]// Proceedings of International Joint Conference on Neural Networks, 2004: 25-29
- [5] Huang G B, Wang D H, Lan Y. Extreme Learning Machines: A

- Survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2):107-122
- [6] Huang G B, Ding X J, Zhou H M. Optimization method based extreme learning machine for classification [J]. Neurocomputing, 2010, 74: 155-163
- [7] Lan Yuan, Yeng C-S, Huang Guang-bin. Ensemble of online sequential extreme learning machine [J]. Neurocomputing, 2009, 73 (13-15): 3391-3395
- [8] Tian Hui-xin, Meng Bo. A new modeling method based on bagging ELM for day-ahead electricity price prediction[C]// 2010 IEEE Fifth International Conference Bio-Inspired Computing: Theories and Applications (BIC-TA). Changsha, China, 2010: 1076-1079
- [9] Tian Hui-xin, Mao Zhi-zhong. An Ensemble ELM Based on Modified AdaBoost. RT Algorithm for Predicting the Temperature of Molten Steel in Ladle Furnace[J]. Automation Science and Engineering, 2009, 7(1): 73-80
- [10] Cao J W, Lin Z P, Huang G B, et al. Voting based extreme learning machine[J]. Information Sciences, 2012, 185(1): 66-77
- [11] 陆慧娟, 安春霖, 马小平, 等. 基于输出不一致测度的极限学习机集成的基因表达数据分类[J]. 计算机学报, 2013, 36: 341-348
- [12] Foggia P, Sansone C, Torella F, et al. Mult-classification: reject criteria for the bayesian combiner[J]. Pattern Recognition, 1999 (32): 1435-1447
- [13] 郑恩辉, 李平, 宋执环. 代价敏感支持向量机[J]. 控制与决策, 2006, 21(4): 473-476
- [14] 邹超, 郑恩辉, 任玉玲, 等. 嵌入误分类代价和拒识代价的二元分类算法[J]. 广西师范大学学报: 自然科学版, 2010, 28(3): 201-208
- [15] 付忠良. 多分类问题代价敏感 AdaBoost 算法[J]. 自动化学报, 2012, 37(8): 973-983
- [16] 史小伍, 陶红, 阚今中, 等. 组合代价敏感支持向量机及其应用[J]. 计算机技术与发展, 2012, 22(5): 71-78
- [17] 万建武, 杨明, 陈银娟. 代价敏感的半监督 Laplacian 支持向量机[J]. 电子学报, 2012, 40(7): 1410-1415

(上接第 210 页)

之上, 比如, 包含带传递闭包构造子的描述逻辑, 就需要在一阶逻辑的语言中增加无穷并加以表达, 而包含无穷并的一阶逻辑不具有紧性<sup>[21]</sup>。因此, 为刻画上述描述逻辑系统的表达能力, 需要给出新的方法。

## 参 考 文 献

- [1] Baader F, Nutt W. Basic description logics[M]// Baader F, Calvanese D, McGuinness D, et al., eds. The Description Logic Handbook: Theory, Implementation, and Applications. Cambridge: Cambridge University Press, 2003
- [2] Horrocks I, Patel-Schneider P F, Harmelen F V. From SHIQ and RDF to OWL: The making of a Web ontology language[J]. Journal of Web Semantics, 2003, 1(1): 7-26
- [3] Baader F, Sattler U. An overview of tableau algorithms for description logics[J]. Studia Logica, 2001, 69(1): 5-40
- [4] Baader F, Brandt S, Lutz C. Terminological cycles in a description logic with existential restrictions[C]// Gottlob G, Walsh T, eds. Proc. of the 18th International Joint Conference on Artificial Intelligence (IJCAI 2003). San Francisco: Morgan Kaufmann Publishers, 2003: 325-330
- [5] 王驹, 蒋运承, 申宇铭. 描述逻辑系统  $\mathcal{FL}$ -循环术语集的可满足性及推理机制[J]. 中国科学(F 辑), 2009, 39(2): 205-211
- [6] 常亮, 史忠植, 陈立民, 等. 一类扩展的动态描述逻辑[J]. 软件学报, 2010, 21(1): 1-13
- [7] 蒋运承, 王驹, 邓培明, 等. 描述逻辑  $\mathcal{FL}$ -循环术语集的语义及推理[J]. 计算机学报, 2008, 31(2): 185-195
- [8] 史忠植, 常亮. 基于动态描述逻辑的语义 Web 服务推理[J]. 计算机学报, 2008, 31(9): 1599-1611
- [9] Ohlbach H, Nonnengart A, de Rijke M, et al. Encoding two-valued non-classical logics in classical logic [M] // Robinson A, Voronkov A, eds. Handbook of Automated Reasoning. Netherlands: Elsevier Press, 2001: 1403-1486
- [10] van Benthem J. Correspondence theory [M]// Gabbay D, Guenther F, eds. Handbook of Philosophical Logic, Vol. 2: Extensions of Classical Logic. Dordrecht, Netherlands: D. Reidel Publishing Company, 1983: 167-247
- [11] Goranko V, Otto M. Model theory of modal logic[M]// Blackburn P, van Benthem J, Wolter F., eds. Handbook of Modal Logic. Netherlands: Elsevier Press, 2007: 246-329
- [12] Baader F. A Formal definition for the expressive power of terminological knowledge representation languages [J]. Journal of Logic and Computation, 1996, 6(1): 33-54
- [13] Borgida A. On the relative expressiveness of description logics and predicate logics[J]. Artificial Intelligence, 1996, 82 (1/2): 353-367
- [14] Kurtonina N, de Rijke M. Expressive of concept expression in first-order description logics[J]. Artificial Intelligence, 1999, 107 (2): 303-333
- [15] Lutz C, Piro R, Wolter F. Description Logic TBoxes: Model-Theoretic Characterizations and Rewritability[C]// Proceeding of the Twenty-Second International Joint Conference on Artificial Intelligence (IJCAI 2011). Barcelona, Catalonia, Spain: AAAI Press, 2011: 983-988
- [16] 申宇铭, 王驹, 唐素勤. 描述逻辑  $\mathcal{ALC}$  概念及术语公理集的表达能力刻画[J]. 软件学报, 2014, 25(8): 1794-1805
- [17] Baader F, Kusters R, Molitor R. Rewriting concepts using terminologies[C]// Proceeding of the 7th International Conference on Principles of Knowledge Representation and Reasoning (KR2000). Brechenridge, Colorado USA: Morgan Kaufmann, 2000: 297-308
- [18] Brandt S, Kusters R, Turhan A-Ya. Approximation and difference in description logic[C]// Proceeding of the 7th International Conference on Principles of Knowledge Representation and Reasoning (KR2002). San Francisco, CA, Morgan Kaufmann, 2002: 203-214
- [19] Lutz C, Wolter F. Deciding inseparability and conservative extensions in the description logic  $\epsilon\mathcal{L}$ [J]. Journal of Symbolic Computation, 2010, 45(2): 194-228
- [20] Kontchakov R, Wotler F, Zakharyashev M. Logic-based ontology comparison and module extraction, with an application to DL-Lite[J]. Artificial Intelligence, 2010, 174(15): 1093-1141
- [21] Ebbinghaus H D, Flum J, Thomas W. Mathematical Logic[M]. Second Edition, Springer, 1994