

一种逻辑强化学习的 tableau 推理方法

刘 全<sup>1,2</sup>, 崔志明<sup>1</sup>, 高 阳<sup>2</sup>, 陈道蓄<sup>2</sup>, 姚望舒<sup>1</sup>

(1. 苏州大学 计算机科学与技术学院, 江苏 苏州 215006; 2 南京大学 软件新技术国家重点实验室, 江苏 南京 210093)

**摘 要:** tableau 方法是一种具有较强的通用性和适用性的推理方法, 但由于函数符号、等词等的限制, 使得自动推理具有不确定性. 针对 tableau 推理中封闭集合构造过程具有盲目性的问题, 提出将强化学习用于 tableau 自动推理的方法. 该方法将 tableau 推理过程中的逻辑公式与强化学习相结合, 产生抽象的状态和活动. 这样一方面可以通过学习方法控制自动推理的推理顺序, 形成合理的封闭分枝, 减少推理的盲目性; 另一方面复杂的推理可以利用简单的推理结果, 提高推理的效率.

**关键词:** 逻辑强化学习; tableau 推理

**中图分类号:** TP301 **文献标识码:** A **文章编号:** 1673-4785 (2008) 04-0355-06

Tableau reasoning method based on logical reinforcement learning

L IU Quan<sup>1,2</sup>, CUI Zhiming<sup>2</sup>, GAO Yang<sup>1</sup>, CHEN Dao-xu<sup>1</sup>, YAO Wang-shu<sup>2</sup>

(1. School of Computer Science of Technology, Soochow University, Suzhou 215006, China; 2 State Key Laboratory for Novel Software Technology, Nanjing University, Nanjing 210093, China)

**Abstract:** The tableau method is a reasoning method with high universality and applicability. However, given the restrictions of function symbols and equations, there remains a great deal of uncertainty in automated reasoning. In order to remove blind reasoning in the construction of a closed set for tableau reasoning, a method was developed to introduce reinforcement learning into tableau reasoning. Reinforcement learning was combined with the logical formulae in tableau reasoning to produce abstract states and actions. On the one hand, reasoning sequences in auto reasoning can be controlled by the learning method to form reasonable closed branches and reduce the blindness of reasoning. On the other hand, simple reasoning results can be reused in the complex reasoning system to improve reasoning efficiency.

**Keywords:** logical reinforcement learning; tableau reasoning

Tableau 方法是 1955 年由 Beth 提出的一种推理方法, 其实质是将语义结构中的关系表现出来, 使证明理论与语义联系起来. 对于不同的逻辑系统, 所使用的 tableau 规则是相同的, 只是对公式构造集进行扩展, 使之更接近相应的逻辑系统. 由于 tableau 方法具有较强的通用性和直观性, 从 20 世纪 60 年代开始, 这种方法引起以 Smullyan、Fitting 为代表的计算

机科学家的兴趣, 同归结一样, 被认为是重要的自动推理方法之一. 近年来, tableau 方法引起了更为广泛的关注, 成为语义 WEB<sup>[1]</sup>、自然语言理解<sup>[2]</sup>、数据库修正<sup>[3]</sup>、模型检测<sup>[4]</sup>等推理系统的核心推理方法.

对于自动推理来说, 考核推理效率的 2 个重要指标就是推理所需要的时间和空间. 在 tableau 推理中也同样存在着效率问题. 如对 公式实例化的次数的限定, 以及 公式中函数符号和自变量的限制, 限制控制处理不得当, 可以使一个简单的证明变得非常复杂, 延迟了 tableau 的封闭时间, 甚至得不到证明. 另外, 由于等词的对称性, 对于含等词的 tableau 会出现搜索空间膨胀, 甚至死循环的现象. 从经典逻辑向非经典逻辑扩展方面看, 虽然经典逻辑的

收稿日期: 2007-10-22.  
基金项目: 国家自然科学基金资助项目 (60673092, 60775046); 教育部重点资助项目 (207040); 中国博士后科研基金资助项目 (20060390919); 江苏省高校自然科学基金资助项目 (06KJB520104); 江苏省博士后科研基金资助项目 (060211C); 江苏省现代企业信息化应用支撑软件工程技术研究中心开发项目 (SX200804).  
通信作者: 刘 全. E-mail: quanliu@suda.edu.cn

相应规则和方法可以直接应用到非经典逻辑中,但是有时会出现大量的冗余分枝,降低计算机的处理效率.近年来,针对 tableau 推理效率问题,在 tableau 推理技术、策略及方法上有大量的研究,并且取得了非常可喜的成果<sup>[5]</sup>.在文献[6]中,针对制约自动推理发展的瓶颈——推理的不确定性问题,提出了推理器与机器学习相结合的未来发展方向.文献[7]、[8]等提出了将归纳学习、决策树学习等方法与模型生成推理方法相结合,用来模拟生物化学反应的过程.文献[9]等提出了将机器学习与推理方法相结合,实现 Web 上智能化搜索.但这些方法大多是针对具体的某类逻辑公式而提出的,缺乏普遍性,仍然不能解决推理中的不确定性问题,不利于计算机实现.

本文在强化学习的基础上,提出针对 tableau 自动推理的逻辑强化学习方法.这种方法,可以从强化学习的层面上找到 tableau 扩展的最佳方法,适用于多种类型的 tableau 推理.该方法对于更大程度地减少 tableau 扩展的盲目性、不确定性,具有重要的意义.

## 1 预备知识

### 1.1 逻辑与 tableau 推理

一阶符号为元数  $m \geq 0$  的关系符号  $P$  的集合及常量  $C$  的集合组成.如果关系符号  $P$  的元数  $m (m \geq 0)$  为 0,则  $P$  称为命题.项是变量  $X$  或常量  $C$ .  $P$  为  $n$  元谓词符号,  $t_1, \dots, t_n$  为项,则  $P(t_1, \dots, t_n)$  为原子,记为  $At$ . 一个替换是形如  $\{t_1/v_1, \dots, t_n/v_n\}$  的一个有限集合,其中  $v_i$  是变量符号,  $t_i$  是不同于  $v_i$  的项,并且在此集合中不存在斜线符号后面相同变量符号的 2 个元素,称  $t_i$  为替换的分子,  $v_i$  为替换的分母,当  $t_1, \dots, t_n$  为基项时,称此替换为基替换.合取  $A$  为原子集合.合取  $A$  称为合取  $B$  的包含,如果存在一个替换,使得  $B \subset A$ ,记为  $A \supset B$ .当项、原子或子句  $E$  不包含变量时称为基例.表达式集合  $\{E_1, \dots, E_k\}$  的合一称为最一般合一,当且仅当对此集合的每一个合一,都存在替换,使得  $E_i = E_j$ .对于原子  $a$  和  $b$  的最一般合一记为  $mgu(a, b)$ .

的 Herbrand 基表示为  $HB$ ,是由所有  $HB$  中谓词和函数符号构成的基原子集合.

令  $\{A_1, A_2, \dots, A_n\}$  为公式的有限集合.下列分枝树为公式  $\{A_1, A_2, \dots, A_n\}$  的一个 tableau:

$A_1$

$A_2$

...

$A_n$

如果  $T$  为  $\{A_1, A_2, \dots, A_n\}$  的一个 tableau,且  $T'$  为  $T$  应用 tableau 扩展规则后的结果,那么  $T'$  也是  $\{A_1, A_2, \dots, A_n\}$  的一个 tableau

利用 tableau 方法进行定理证明,将被证明的公式分为 4 类,即  $\neg$ 、 $\vee$ 、 $\wedge$ 、 $\rightarrow$  公式,各类公式对应的规则为<sup>[10]</sup>

—

...

$n$

$\neg$ -规则、 $\vee$ -规则与  $\wedge$ -规则分别为

$$\frac{}{1 / \dots / n \quad 1(y) \quad 1(f(x_1, \dots, x_n))}$$

式中:  $y$  是一个自由变量,  $f$  是一个新 skolem 函数符号,  $x_1, \dots, x_n$  是分枝中出现的自由变量.

### 1.2 强化学习

强化学习是一种从环境状态到动作映射的学习<sup>[11]</sup>.其主要解决的问题是:一个能够感知环境的自治 Agent,如何通过学习选择达到其目标的最优动作.类似问题普遍存在于自动控制、工序优化、棋类对弈等领域. Agent 在其环境中作出每个动作时,会从环境中得到奖励或惩罚信息,以表示结果状态的正确与否. Agent 的任务是从这个非直接的有延迟的回报中学习,以便后续的动作产生最大的累积回报<sup>[12]</sup>.标准的 Agent 强化学习框架结构如图 1 所示.




图 1 标准的 Agent 强化学习框架结构

Fig 1 The framework of standard Agent reinforcement learning

Agent 学习可以表述为马尔可夫决策过程 (Markov decision process, MDP), MDP 是一个元组  $M = (S, A, T, R)$ , 这里  $S$  是系统状态集;  $A$  是活动集,对于每个状态  $s \in S$ , Agent 都可以得到一个有穷

的活动集  $A(s) \subseteq A$ ;  $T$  为迁移, 对于每个  $s, s' \in S$  和  $a \in A(s)$ , 都存在一个迁移  $T$ , 使得状态从  $s$  转移到  $s'$ , 即表示为  $s \xrightarrow{p, r, a} s'$ . 这里  $p$  表示由活动  $a$  引起的从状态  $s$  迁移到  $s'$  的概率, 且对于每个  $s \in S, a \in A$  都满足  $\sum_{s'} p(s, s', a) = 1$ . 对于每个迁移, Agent 都可以获得一个立时回报  $R(s, a, s') = r$ . 在这种情况下, 回报函数  $R$  只依赖于目前的状态和活动, 如果  $R$  是概率的, 那么称它为非确定性的, 否则称为确定性的. 一个策略  $\pi: S \rightarrow A$ , 它基于当前观察到的状态  $s_t$  选择下一步动作  $a_t$ , 即  $\pi(s_t) = a_t$ . 因此 Agent 的任务是找到一个策略  $\pi^*$ , 使得对于所有的状态  $s_t \in S$ , 值函数  $V(s_t)$  最大.  $V(s_t)$  主要有以下 3 种形式:

折算累积回报: 
$$V(s_t) = \sum_{i=0}^{\infty} \gamma^i r_{t+i},$$

有限水平回报: 
$$V(s_t) = \sum_{i=0}^h r_{t+i},$$

平均回报: 
$$V(s_t) = \lim_{h \rightarrow \infty} \frac{1}{h} \sum_{i=0}^h r_{t+i}.$$

这里使用的未解释的记号和概念, 请参见文献 [7] 和 [12].

2 逻辑强化学习

MDP 的逻辑组成对应于一个有穷的状态机, 由于状态和活动是非结构的, 因此这个自动机必须是以命题表示. 通过逻辑马尔可夫决策程序 (logical Markov decision process, LOMDP) 可以通过逻辑符号来替代同类状态和活动, 最大程度地减少状态和活动的数量.

定义 1 令  $\mathcal{L}$  为逻辑,  $\mathcal{A}$  为  $\mathcal{L}$  中的定理,  $P$  为  $\mathcal{L}$  中的谓词集合,  $C$  为  $\mathcal{L}$  中的常量集合,  $\hat{A}$  为  $\mathcal{L}$  中的特定的活动谓词集合. 逻辑马尔可夫决策程序 (LOMDP) 定义为  $M_{LO} = (S_{LO}, A_{LO}, T_{LO}, R)$ , 其中  $S_{LO} = \{s \mid \text{HB}^P C \mid s \models \cdot\}$ ,  $A_{LO} = \{a \mid \text{HB}^{\hat{A}} C \mid a \models \cdot\}$ ,  $T_{LO}: S_{LO} \times A_{LO} \times S_{LO} \rightarrow [0, 1]$ .

定义 2 抽象状态是一个逻辑原子的合取式, 即逻辑查询. 这里空合取记为  $\emptyset$ .

抽象状态表示状态集, 状态  $S_{LO}$  是在  $\mathcal{L}$  上的一个基例的有穷合取, 即 Herbrand 子集上的逻辑解释. 在一个含等词的逻辑公式  $\{(\forall x)((g(x) \rightarrow f(x)) \rightarrow (x = a)), (\forall x)(g(f(x)) \rightarrow x), b = c, P(g(g(a)), b), \neg P(a, c)\}$  中, 一个可能的抽象状

态  $s_{LO}$  是  $\{g(f(x_1)) \rightarrow x_1, g(x_2) \rightarrow f(x_2), P(g(f(a)), b)\}$ . 如果一个可能状态中存在互补对, 那么该状态称为封闭状态. 抽象状态  $\{ \neg P(a, c), g(f(x_1)) \rightarrow x_1, g(x_2) \rightarrow f(x_2), P(g(f(a)), b), P(a, b), P(x_2, c) \}$  在替换  $a/x_2$  后, 是封闭状态.

定义 3 一个抽象迁移  $T_{LO}$  的形式为  $B_{LO} \xrightarrow{p, r} H_{LO}$ , 这里  $P(T_{LO}) = p \in [0, 1], R(T_{LO}) = r \in [0, 1], a$  是一个抽象活动, 且  $\text{body}(T_{LO}) = B_{LO}$  且  $\text{head}(T_{LO}) = H_{LO}$  是抽象状态, 这里,  $\text{body}/1$  和  $\text{head}/1$  为 2 个一阶谓词.

假设  $T_{LO}$  的范围是受限的, 即  $\text{vars}(H_{LO}) \subseteq \text{vars}(B_{LO})$  且  $\text{vars}(a) \subseteq \text{vars}(B_{LO})$ ,  $\text{vars}/1$  为一个受限一阶谓词. 则抽象转换只依赖于目前状态的信息编码. 抽象转换的主要思想是:

如果 Agent 处于状态  $Z$ , 使得  $B \subseteq Z$ , 那么活动  $a$  在概率  $p$  下, 将转移到状态  $Z' = [Z \setminus B] \cup H$ , 得到的直接回报为  $r$ .

在 tableau 推理中, 引起状态迁移的惟一原因是扩展规则的使用, 即  $\neg$  规则在抽象状态内部, 使得合取元素得到扩展,  $\neg$  规则可以使一个抽象状态分解为多个状态,  $\neg$  规则和  $\neg$  规则分别引入了自变量和函数符号.

为了说明问题, 考虑下面的抽象迁移, 上述含等词公式由一种状态迁移到另一种状态:

$$\{(\forall x)((g(x) \rightarrow f(x)) \rightarrow (x = a)), (\forall x)(g(f(x)) \rightarrow x), b = c, p(g(g(a)), b), p(a, c)\} \xrightarrow{0.9, -1, \text{rl\_alfa}} \{(\neg(g(x_2) \rightarrow f(x_2)) \rightarrow (x_2 = a), g(f(x_1)) \rightarrow x_1, b = c, p(g(g(a)), b), \neg p(a, c)\}.$$

应用到状态  $\text{Exp}$ :  $\{(\forall x)((g(x) \rightarrow f(x)) \rightarrow (x = a)), (\forall x)(g(f(x)) \rightarrow x), b = c, p(g(g(a)), b), \neg p(a, c)\}$ .

当执行抽象迁移  $\text{rl\_alfa}$  后, 后继状态为  $\{(\neg(g(x_2) \rightarrow f(x_2)) \rightarrow (x_2 = a), g(f(x_1)) \rightarrow x_1, b = c, p(g(g(a)), b), \neg p(a, c)\}$ . 转换概率为 0.9, 获得直接回报为 -1.

下面是基于逻辑强化学习的 tableau 算法.  
算法 1:  
初始化  $Q_0$ , 对所有的  $(s, a)$  赋初值 0

```
e:=0
do forever
e:=e+1
i:=0
产生一个随机状态  $s_0$ 
while not close( $s_i$ ) do /*判断是否为封闭状态
* /
选择 tableau 规则  $a_i$ 
执行规则  $a_i$ 
接收到立即回报  $r_i = r(s_i, a_i)$ 
观察新状态  $s_{i+1}$ 
i:=i+1
endwhile
for j=i-1 to 0 do
产生实例  $x = (s_j, a_j, q_j), q_j := r_j + \max_{a_i} Q_e(s_{j+1}, a)$ 
```

如果实例中存在  $(s_j, a_j, q_{old})$ , 那么用  $x$  来替换它, 否则加入  $x$

对于一个简单的例子  $(p(x) \rightarrow q(x)) \rightarrow p(a) \rightarrow q(a)$ , 可以使用算法 1 产生一个 tableau 过程, 如表 1 所示.

表 1 公式  $(p(x) \rightarrow q(x)) \rightarrow p(a) \rightarrow q(a)$  的基于逻辑强化学习的 tableau 过程

Table 1 Tableau process based on logical reinforcement learning of fomula $(p(x) \rightarrow q(x)) \rightarrow p(a) \rightarrow q(a)$			
Example 1	Example 2	Example 3	Example 4
Qvalue (0.81)	Qvalue (0.9)	Qvalue (1.0)	Qvalue (1.0)
rl_alfa	rl_alfa	rl_beta	rl_beta
$(p(x) \rightarrow q(x)) \rightarrow p(a)$	$p(x) \rightarrow q(x)$	$p(x)$	$q(a)$
$q(a)$	$p(a)$	$p(a)$	$p(a)$
	$q(a)$	$q(a)$	$q(a)$
在替换 $x/a$ 下, 为封闭状态			封闭状态

定理 1 每一个 LOMDP 中  $M_{LO} = (S_{LO}, A_{LO}, T_{LO}, R)$  对应于一个离散的  $M = (S, A, T, R)$ .

证明 令  $HB^S \subseteq HB$  为抽象状态谓词的所有基原子的集合,  $HB^a \subseteq HB$  为抽象活动谓词的所有基原子的集合. 状态集合  $S_{LO}$  都包含在有穷的集合  $HB^S$  中, 活动集合  $a$  都包含在有穷的集合  $HB^a$  中, 一个抽象迁移  $T_{LO}$  是一个形式为  $B_{LO} \xrightarrow{p, r} H_{LO}$ , 其中  $B_{LO}$  和  $H_{LO}$  都为抽象状态,  $a$  为抽象活动,  $M_{LO}$  中的  $R$  与  $M$  中的  $R$  相同. 因此可以看出,  $M_{LO}$  和  $M$  中的四

元组的元素有对应关系, 每一个 LOMDP  $M_{LO} = (S_{LO}, A_{LO}, T_{LO}, R)$  对应于一个离散的  $M = (S, A, T, R)$ , 证毕.

引理 1 给定一个 tableau 抽象状态序列  $(S_j)_{0 \leq j \leq n}$ , 如果 tableau  $S_j (0 \leq j \leq n)$  是可满足的, 那么 tableau  $S_{j+1}$  也是可满足的.

证明 令  $B$  是通过应用经典扩展规则或定理扩展规则形成的抽象活动, 从抽象状态  $S_i$  到  $S_{i+1}$  的分枝, 应用定理封闭规则可以删除封闭分枝. 令  $M = D, I$  为可满足  $S_i$  的结构.

令  $v$  为任意变量, 应用  $\neg$  规则, 在  $S_i$  中必然存在分枝  $B$  使得  $(M, v) \models B$ , 如果  $B$  不同于  $B$ , 那么  $B = S_{i+1}$ .

另外, 如果  $B = B$ , 那么  $(M, v) \models B$ . 令  $\neg$  为在  $B$  中应用  $\neg$  规则得到的公式, 根据  $\neg$  公式的性质,  $(M, v) \models \neg$  必然有  $(M, v) \models \neg_1$  或  $(M, v) \models \neg_2$ , 因此有  $(M, v) \models (B \setminus \{ \neg \}) \vee \neg_1$  或  $(M, v) \models (B \setminus \{ \neg \}) \vee \neg_2$  存在, 因此  $(B \setminus \{ \neg \}) \vee \neg_1$  和  $(M, v) \models (B \setminus \{ \neg \}) \vee \neg_2$  在  $S_{i+1}$  中.

和  $\neg$  规则证明与  $\neg$  规则证明相类似.

令  $\neg$  为应用  $\neg$  规则从  $S_i$  到  $S_{i+1}$  得到的公式,  $\neg_1(f(x_1, \dots, x_m))$  为加到分枝中的公式 ( $f$  是新的 skolem 函数符号, 且  $x_1, \dots, x_m$  是在  $S_i$  中的自由变量). 定义一个不同于  $M$  的结构  $M = D, I$ , 除了新的函数符号  $f$  由  $I$  解释外, 其他按如下方法定义: 对于在区间  $D$  中的每个元素集  $d_1, \dots, d_m$ , 如果存在一个元素  $d$  使得  $(M, v) \models \neg_1(x)$ , 这里  $(x_j) = d_j (1 \leq j \leq m)$  且  $(x) = d$ , 那么  $f^I(d_1, \dots, d_m) = d$ . 如果不存在如此元素  $d$ , 可选其中之一, 如果不存在此类元素, 可以在区域中选择任意元素. 对于所有的变量赋值  $v$ : 如果  $(M, v) \models \neg$ , 那么  $(M, v) \models \neg_1(f(x_1, \dots, x_m))$ . 由于  $f$  不出现在  $S_i$  中, 故  $M$  为  $S_{i+1}$  结构.

令  $v$  为任意变量赋值, 在  $S_i$  中必然存在分枝  $B$ , 使得  $(M, v) \models B$ , 如果  $B$  不同于  $B$ , 那么  $(M, v) \models B$  ( $f$  不出现在  $B$  中) 且  $B = S_{i+1}$ .

当  $B = B$ , 必然有  $(M, v) \models \neg$ ,  $(M, v) \models \neg_1(f(x_1, \dots, x_m))$ , 这样  $(B \setminus \{ \neg \}) \vee \neg_1(f(x_1, \dots, x_m))$  在  $S_{i+1}$  的一个分枝上, 并且由  $M$  满足.

定理扩展规则: 令反驳  $\neg, \{ \neg_1, \dots, \neg_k \}$  用于扩展 tableau, 由于  $S_i$  为可满足的, 那么  $S_i$  也是可满足的. 令  $M$  为结构满足  $S_i$ , 且  $v$  为任意变量

赋值,那么必然有分枝  $B \vdash S_i$ ,且  $(M, v) \models B$ .

根据 公式的定义,有  $B \models \varphi(\forall x_1^i) \dots (\forall x_m^i) \neg p$ 使得  $B \models \varphi(\forall x_1^i) \dots (\forall x_m^i) \neg p$ ,即  $(M, v) \models$ ,这里  $\varphi = \{(\forall x_1^i) \dots (\forall x_m^i) \neg p\}$ ,因为  $\{ \varphi_1, \dots, \varphi_k \}$  为 的反驳,使得  $\vdash \varphi_1 \dots \varphi_k$ ,对于某一  $j \in \{1, \dots, k\}$ ,必有  $(M, v) \models \varphi_j$ ,即  $M$  满足  $S_{i+1}$ 中的分枝  $B \vdash \{ \varphi_j \}$ .

证毕.

定理 2 如果对于公式 存在一个 tableau 抽象状态证明序列  $\{ \varphi \} = S_0, S_1, \dots, S_{n-1}, S_n = \emptyset$  ( $n > 0$ ),那么 是一个 重言式.

证明 是 不可满足的,那么根据引理 1,  $T_n$  也是 不可满足的,依次类推,  $S_{n-1}, \dots, S_1, S_0$  是 不可满足的.这样,第 1 个 tableau  $\{ \varphi \}$ 也是 不可满足的,即 是 不可满足的,这等价于是 不可满足的.证毕.

3 实验结果

将基于逻辑强化学习的 tableau 方法应用于 TableauTAP 系统<sup>[13]</sup>中,在 Windows 环境下,应用 SWI-PROLOG 语言对该系统进行了实现,主要是将基于强化学习的 tableau 过程自动生成 Prolog 程序,并与原系统中的推理规则相结合,形成一个可运行的推理程序.应用改进后的系统对 TPTP 自动推理测试库中的 400 个问题进行了证明,并与原系统进行了对比,结果见表 2.

表 2 TPTP 中定理的证明结果对比表

Table 2 The theorem proving results contrast in TPTP

算 法	ValLim 限定次数	测试 封闭分枝数	封闭分 枝数	CPU 时 间 / s	占内存空 间 / byte
改进 TableauTAP	982	1 354	457	123 243	9 512
原 TableauTAP	1 560	10 230	5 020	845 891	205 422

从表 2 中可以看出,改进后的 TableauTAP 的几项指标均优于原系统,尤其是在 CPU 时间方面,由于 TableauTAP 具有学习功能,后继的证明可以学习到前面的证明结论,因此运行速度要比原系统高得多.同时由于该方法的普遍性,使得编程时不需要针对不同的逻辑系统考虑太多的情况,使得程序代码比其他的系统要小得多,也更容易应用到自动推理

作为推理机的实际应用系统中.

4 结束语

本文提出了将逻辑强化学习用于 tableau 推理的方法,对处理 tableau 推理的盲目性具有一定的价值.但该研究只是相关研究的开端,正在研究和将要研究的内容主要包括以下几方面:1)拟采用 tableau 推理模型对逻辑状态和逻辑活动进行建模,研究一种新的函数估计模型,使其一方面能够以任何精度逼近理论的强化学习值函数,另一方面在增量环境中保证收敛性.2)拟将布尔剪枝、IP-tableau 等方法与逻辑强化学习相结合,对逻辑状态空间模型进行相应的等价转换,采用解线性方程组的方式来简化状态空间,降低状态空间维数,解决大规模、连续的 MDP 问题.在 tetris 问题中,试验所设计的强化学习框架和算法,并对比收敛速度.3)结合所研究的模型和算法,研究一种面向 Deep Web 搜索引擎的自适应爬虫搜索算法.在模型不确定的情况下,寻找满足搜索算法的优化目标的最优策略,达到爬虫总搜索路径最短、搜索无关页面最低等,并在性能上对比目前常用的几种爬虫调度算法.

参考文献:

[1] 史忠植,董明楷,蒋运承,张海俊. 语义 Web 的逻辑基础 [J]. 中国科学 (E 辑), 2004, 34 (10): 1123-1138  
SHI Zhongzhi, DONG Mingkai, JIANG Yuncheng, ZHANG Haijun. A logic foundation for the semantic web [J]. Science in China (Series E), 2004, 34 (10): 1123 - 1138.

[2] BLACKBURN P, BOS J. Representation and inference for natural language [C]// CSLI Publications, Crysmann, Berthold, 2005.

[3] BERTOSSI L, SCHWEND C. Analytic tableaux and database repairs [C]//Foundations of Information and Knowledge Systems Springer LNCS 2284, 2003.

[4] 苏开乐,骆翔宇,吕关锋. 符号化模型检测 CTL [J]. 计算机学报, 2005, 28 (11): 1798-1806  
SU Kaile, LUO Xiangyu, LU Guanfeng. Symbolic model checking for CTL [J]. Chinese Journal of Computer, 2005, 28 (11): 1798-1806.

[5] PASKEVICH A. Connection tableaux with lazy paramodulation [C]// IJCAR 2006 Seattle, USA, 2005.

[6] HORVITZ E. Machine learning, reasoning, and intelligence in daily life: directions and challenges [C]//Proceedings of

LML, Bled, Slovenia, 1999.

- [7] BRYANT C, MUGGLETON S, OLIVER S. Combining inductive logic programming, active learning and robotics to discover the function of genes[J]. Electronic Transactions in Artificial Intelligence, 2001, 6(12): 1-36
- [8] CALZONE L, CHABRIER N, FAGES F. Machine learning biomolecular interactions from temporal logic properties [C]//Proceedings of CMSB 2005. Edinburgh, Scotland, 2005.
- [9] TEEVAN J, HORVITZ E. Personalizing search via automated analysis of interests and activities[C]//Proceedings of SIGIR. Salvador, Brazil, 2005: 449-456
- [10] FITTING M. First order logic and automated theorem proving[M]. New York: Springer-Verlag, 1996
- [11] 高 阳, 陈世福, 陆 鑫. 强化学习综述 [J]. 自动化学报, 2004, 30(1): 86-100.
- GAO Yang, CHEN Shifu, LU Xin. Research on reinforcement learning technology: a review [J]. Acta Automatica Sinica, 2004, 30(1): 86-100
- [12] OTTERLO M. Reinforcement learning for relational MDPs [C]//Machine Learning Conference of Belgium and the Netherlands (BeNeLeam '04). [S.l.], 2004: 138-145.
- [13] 刘 全, 孙吉贵. 基于 Tableau 的定理机器证明系统 TableauTAP[J]. 计算机工程, 2006, 32(7): 38-45
- LU Quan, SUN Jigui. Theorem proving system based on TableauTAP[J]. Computer Engineering, 2006, 32(7): 38 - 45

#### 作者简介:



刘 全,男,1969年生,教授,博士后,中国计算机学会高级会员,主要研究方向为智能信息处理、自动推理、机器学习.主持和参与国家级科研项目 4 项,主持省部级和市(局)级科研项目 10 多项,获省部级科技进步奖 2 项,市(局)级科技进步奖 8 项.发表学术论文 40 余篇,其中 SCI 收录 4 篇, EI 收录 20 篇.



崔志明,男,1961 年生,教授,博士生导师,中国计算机学会高级会员,主要研究方向为模式识别、Deep Web.主持国家级及省部级科研项目 18 项.作为项目负责人完成并通过省(部)级以上鉴定的项目有 28 项,并获国防科工委科技进步一等奖 1 项、省部级科技进步

二等奖 2 项、三等奖 4 项、省优秀软件三等奖 2 项;发表学术论文 100 余篇,其中被 SCI、EI 收录 28 篇,出版著(译)作 13 部,申请发明专利 4 项,获软件著作权 6 项.



高 阳,男,1972 年生,副教授,博士,中国人工智能学会理事,中国机器学习专业委员会常务委员,主要研究方向为强化学习、多 Agent 系统.发表学术论文 50 余篇.

## The Sino-European Workshop on Intelligent Robots and Systems (SEIROS'08)

### 第一届中欧智能系统及机器人国际学术研讨会

第一届中欧智能系统及机器人国际学术研讨会将于 2008 年 12 月 11~13 日在重庆邮电大学举行.此次学术论坛是由英国 Oxford 大学、英国 Essex 大学、德国 Hamberg 大学、瑞士苏黎世联邦高等工业大学等国际著名大学的智能系统及机器人技术专家发起,响应科技部关于“中欧科技年”2008 年活动的建议,旨在为全球智能系统及机器人的专家、学者和工程技术人员提供一个学术交流、研讨平台和应用成果的展示平台,促进国际科技合作和学术交流.

征文范围:智能机器人技术、机器人感知技术、仿生机器人、受生物启发的控制技术、基于人工神经网络、模糊、遗传算法的仿生机器人技术、服务机器人、医疗手术机器人、类人机器人、多机器人协作、智能人机交互、智能信息处理、图像处理与模式识别、机电一体化、智能控制与自动化、智能复杂系统.

截稿日期:2008-10-10

论文录用通知日期:2008-11-10

联系人:徐晓东 李 敏

联系电话:023 - 62471421

E-mail: seiros08@cqupt.edu.cn