

# 一种用于上下文推理的带反馈的自适应模糊 Petri 网模型\*

文赛平<sup>+</sup>, 朱珍民, 叶剑

(中国科学院 计算技术研究所, 北京 100090)

## A Feedback Adaptive Fuzzy Petri Net Model for Context Reasoning

WEN Sai-Ping<sup>+</sup>, ZHU Zhen-Min, YE Jian

(Institute of Computing Technology, The Chinese Academy of Sciences, Beijing 100190, China)

+ Corresponding author: wensaiping@ict.ac.cn, http://www.ict.ac.cn

Wen SP, Zhu ZM, Ye J. A feedback adaptive fuzzy Petri net model for context reasoning. *Journal of Software*, 2010,21(Suppl.):310-317. <http://www.jos.org.cn/1000-9825/10032.htm>

**Abstract:** As an improved model of fuzzy Petri net, adaptive Petri net (AFPNet) has got the learning ability from neural network. But AFPNet still depends on offline training data, while actual environment is so complex, vague and changeful that AFPNet seems slightly inadequate. This paper proposes an approach based on fuzzy logic and feedback theory to improve AFPNet. The approach introduces feedback mechanisms into AFPNet to enhance the adaptive ability in dynamic environment. In addition, the approach embeds fuzzy logic theory into the representation of context information. Thus, the uncertain context information management is more conformable with person's sense. The approach is also able to learn the parameters of membership function by using the back propagation algorithm of neural network. At the end of the paper, an experiment is designed to demonstrate that the approach is feasible and effective in fuzzy reasoning.

**Key words:** fuzzy inference rule; fuzzy logic; neural network; back propagation

**摘要:** 自适应模糊 Petri 网兼具模糊 Petri 网的模糊推理能力和神经网络的学习能力,是普适计算的模糊情境推理机制的重要的形式化规约工具.但该模型依赖于离线训练数据集,无法适应动态变化的普适智能环境.在自适应学习 Petri 网模型中嵌入反馈机制,并对将模糊逻辑引入对上下文的表示,利用神经网络的反向传播学习方法对隶属度函数的参数进行学习,提高了模型的场景适配和个性化自学习能力.通过设计服务推荐系统,建立了模型仿真与验证实验环境.实验结果表明,该方法可以有效提高系统学习能力,进而提高推理正确率.

**关键词:** 模糊推理规则;模糊逻辑;人工神经网络;反向传播算法

上下文感知计算(context awareness computing)是普适计算研究的一个热点问题,指系统能发现和有效利用上下文信息,并用于计算的一种模式,使系统更加智能、方便和交互.Dey<sup>[1]</sup>将上下文定义为任何用于表征实体状态的信息,这里的实体可以是个人、位置、物理的或者信息空间中的对象.然而上下文主要是由各种各样的传感器获得的,由于传感器自身的特性和上下文的传播,使得上下文具有不确定性,并成为上下文感知系统(context awareness system)不得不面对的一个挑战.Henricksen<sup>[2]</sup>将不确定的上下文分为如下 4 类:未知的上下文;歧义的上下文;不准确的上下文和错误的上下文.直接在上下文感知系统中使用上述上下文,容易导致系统

\* Supported by the National High-Tech Research and Development Plan of China under Grant No.2009AA011902 (国家高技术研究发展计划(863)); the National Natural Science Foundation of China under Grant No.61070109 (国家自然科学基金)

Received 2010-07-01; Accepted 2010-12-10

决策错误,甚至引起系统崩溃.上下文推理(context reasoning)正是面向处理不确定的上下文的一种方法,通过解释、综合和推理各种上下文,得出高级的上下文和服务.

近年来,许多研究人员在上下文推理方面做了大量的工作.本体的推理方法是基于 RDF<sup>[3]</sup>和 OWL<sup>[4]</sup>对上下文的形式化描述,以检索最切合的上下文信息和推理得到新的隐含知识,著名的本体推理工具有 FaCT<sup>[5]</sup>和 RACER<sup>[6]</sup>;分布式推理方法充分利用分布式的稳定和可靠的优点,如 Semantic Spaces<sup>[7]</sup>;基于规则的推理方法是将已有的事实同预定义的规则进行匹配而产生出新的知识,该方法具有明显直观、推理清楚、能有效表达启发式知识、模块性强等优点,可有效解决上下文推理方法中推理能力差和不确定性.许多系统都是基于此推理方法构建的<sup>[8-10]</sup>.

基于规则的推理方法是利用预定义的规则来推荐内容,一个规则本质上是一个 If-Then 语句,根据预定义的前提条件得出相应的动作或结论.由于 If-Then 结构接近于人的思维和自然推理形式,易于理解,易于实现人机对话,并且很容易由 Petri Net(PN)<sup>[11]</sup>建模.我们的研究工作就是基于规则的推理方法,在 PN 的基础上开始的.

本文第 1 节简要分析 PN 的发展历程.第 2 节简述自适应模糊 Petri 网(adapt fuzzy Petri nets,简称 AFPN),并对反向传播学习算法作简单介绍.第 3 节提出带反馈的模糊 Petri 网自适应学习方法(feedback adaptive fuzzy Petri nets,简称 FAFPN),对 AFPN 进行改进,在该方法中加入反馈机制,将模糊逻辑理论引入对上下文的表述,并利用反向传播算法对其参数进行训练学习,使得上下文描述更加方便.第 4 节设计实验环境,并进行测试分析,取得比较好的实验结果.最后总结全文,并对下一步工作进行展望.

## 1 相关工作

PN 能够很好地基于规则建模,并能清晰地表示逻辑关系.然而对于不确实的环境,问题将变得十分复杂.Yu<sup>[12]</sup>提出了用隶属度函数来模糊上下文的方法以增强对上下文的表达能力;Chen<sup>[11]</sup>在 PN 的基础上提出了模糊 Petri 网(fuzzy Petri net,简称 FPN),FPN 是基于模糊产生式规则库进行知识推理的很好的建模工具,因而在普适计算的模糊情境推理规约中得到广泛应用.但其缺乏自学习能力,均由先验知识设定权值,无法对复杂多变的上下文进行推理.Li 在 FPN 的基础上引入神经网络技术,形成了一种自适应模糊 Petri 网(adapt fuzzy Petri nets,简称 AFPN)模型.该模型将神经网络中的反向传播(back propagation,简称 BP)算法引入到 FPN 模型中,并对 FPN 中的权值进行反复的学习训练<sup>[13,14]</sup>,得到使推理结果在允许误差范围内的权值,这样就避免了依靠先验经验设置带来的不确定性.

然而 AFPN 仍依赖于离线训练集数据,无法适应动态变化的场景和个性化推荐,而且在 AFPN 中是通过真实度来描述客观数据的不确定性,但并未给出如何推导真实度.为此,本文在 AFPN 的基础上提出了带反馈的模糊 Petri 网自适应学习方法(feedback adaptive fuzzy Petri nets,简称 FAFPN),即在 AFPN 中加入反馈机制,通过调节反馈学习效率来控制 and 适应动态场景;而且将模糊逻辑理论引入对客观数据的描述,使得更能符合人们的认知.在客观数据的表示中加入模糊逻辑,使得简单数据值变成了一组语义值,并且每个语义值都带有一定的真实度<sup>[12]</sup>.

## 2 AFPN

AFPN 建模十分符合人类的思维和认知方式,并能很好地处理并行和并发行为;并借用神经网络的 BP 算法,使其能具有一定的自适应能力.

### 2.1 AFPN简介

AFPN 由 9 元组构成,即  $AFPN = \{P, T, D, I, O, \alpha, \beta, Th, W\}$ ,其中  $P = \{p_1, p_2, \dots, p_n\}$ ,表示库所结点的有限集合;  $T = \{t_1, t_2, \dots, t_n\}$ ,表示变迁结点的有限集合;  $D = \{d_1, d_2, \dots, d_n\}$ ,表示命题的有限集合,且  $|P| = |D|$ ,  $P \cap T \cap D = \emptyset$ ;  $I(O) = T \rightarrow P^*$ ,是输入(输出)函数,反映变迁到库所的映射;  $\alpha = P \rightarrow [0, 1]$ ,是库所对应的命题的真实度;  $\beta = P \rightarrow D$ ,是一个映射,反映库所结点和命题之间的一一对应关系;  $Th: T \rightarrow [0, 1]$ ,也是一个映射,是对

任意变迁结点  $t_i(t_i \in T)$  定义的一个阈值  $\lambda_i, Th = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$ ;  $W = W_i \cup W_o$ , 且  $W_i = I \rightarrow [0,1]$  和  $W_o = O \rightarrow [0,1]$  是输入输出权值的集合.图 1 给出了在表 1 中所示的模糊规则下的 AFPN 图.

**Table 1** Sample of fuzzy inference rules

表1 模糊规则示例

Rules	Description
Rule a	IF A AND B THEN D ON $(\lambda_1, \mu_1)$
Rule b	IF C THEN E ON $(\lambda_2, \mu_2)$
Rule c	IF D AND E THEN G ON $(\lambda_3, \mu_3)$
Rule d	IF F THEN G ON $(\lambda_4, \mu_4)$

在 AFPN 中,每条规则对应一个单元,并且其中输出结果的单元为输出单元,如图 1 中是规则 c 和规则 d 对应的单元,其他单元为隐藏单元,如图 1 中规则 a 和规则 b 对应的单元.  $\forall t \in T$ , 如果  $P_{ij} \in I(t)$ ,  $\sum_{j=1}^n \alpha(P_{ij} \cdot W_{ij}) \geq Th(t)$ ,  $j=1,2,\dots,n$ ,其中  $n$  表示输入库所的数目,则称引燃此结点,且输出库所的真实度  $\alpha(P_{oi})$  如公式(1)中定义.如果有多个输出对应同一个输出库所,如图 1 中规则 c 与规则 d 对应同一个输出库所 d,  $\alpha(P)$  取所有输出真实度中最大的一个,即可由公式(2)表示,其中  $k$  表示该输出库所对应的规则数.

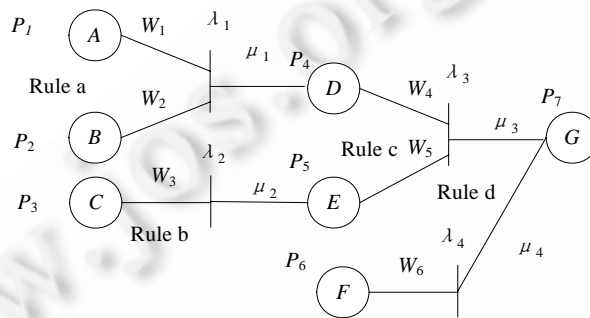


Fig.1 AFPN model structure

图 1 AFPN 模型图

$$\alpha(P_{oi}) = \frac{1}{1 + e^{\mu_i \cdot \sum_{j=1}^n (\alpha(P_{ij}) \cdot W_{ij})}} \tag{1}$$

$$\alpha(P) = \max(\alpha(P_{o1}), \alpha(P_{o2}), \dots, \alpha(P_{ok})) \tag{2}$$

**2.2 反向传播学习**

AFPN 的权值  $W$  表示了每个条件对结论的影响,此值不容易确定,都是根据经验知识决定的,而 AFPN 具有神经网络的某些特性,因此可以借用神经网络的学习算法训练学习,自适应的调整 Petri 网结构中的  $W$  值.在本文中,采用的是反向传播算法来调节权值.

设 AFPN 模型分为  $n$  层,有  $b$  个终止库所  $P_j, j=1,2,\dots,b$ .用  $r$  批样本数据进行学习,取误差代价函数为  $E$ ,如公式(3)中定义,其中  $\alpha_i(P_j)$  和  $\alpha_i^{(1)}(P_j)$  分别表示为终止库所  $P_j$  的第  $i$  批样本数据实际标记值和期望标记值.

$$E = \frac{1}{2} \sum_{i=1}^r \sum_{j=1}^b (\alpha_i(P_j) - \alpha_i^{(1)}(P_j))^2 \tag{3}$$

若  $t_i(n)$  是 AFPN 的第  $n$  层的一个变迁,  $t_i(n) \in T, t_i(n)$  的输入弧上的权值分别为  $W_{i1}^{(n)}, W_{i2}^{(n)}, \dots, W_{im}^{(n)}$ ,那么误差一阶梯度如公式(4)所示,其中  $x=1,2,\dots,m-1$ .在  $n-1$  层上的变迁的一阶梯度同公式(4)类似,如公式(5)中所示,

其中  $x=1,2,\dots,m-1$ .据此继续反推,依次可对所有的一阶梯度  $\frac{\partial E}{\partial W_{ix}^{(q)}}$  值,其中  $x=1,2,\dots,m-1, q=n-2, n-3, \dots, 2, 1$ .

$$\frac{\partial E}{\partial W_{ix}^{(n)}} = \frac{\partial E}{\partial (\alpha^{(n)}(P_j))} \cdot \frac{\partial (\alpha^{(n)}(P_j))}{\partial W_{ix}^{(n)}} \tag{4}$$

$$\frac{\partial E}{\partial W_{ix}^{(n-1)}} = \frac{\partial E}{\partial(\alpha^{(n)}(P_j))} \cdot \frac{\partial(\alpha^{(n)}(P_j))}{\partial(\alpha^{(n-1)}(P_j))} \cdot \frac{\partial(\alpha^{(n-1)}(P_j))}{\partial W_{ix}^{(n-1)}} \quad (5)$$

求出所有的一阶梯度后,对每个变迁的  $t_i(q)$  的权值  $W_i(q)$  参数进行学习调整,如公式(6)中所示,其中  $\eta$  为训练学习效率,  $x=1,2,\dots,m-1, q=n-2,n-3,\dots,1$ . 如此通过多次反复学习,当误差代价函数的值小于接受标准即  $E < \varepsilon$  ( $\varepsilon$  为接受标准)时,停止学习.

$$W_{ix}^{(q)}(k+1) = W_{ix}^{(q)}(k) - \eta \frac{\partial E}{\partial W_{ix}^{(q)}} \quad (6)$$

### 3 改进学习

在 FAFPN 中,其框架是基于模糊产生式规则(If-Then 语句)的知识结构.由于先将客观数据做了模糊化,从而使一组简单的客观数据对应多条规则,即可能输出多种结论,而且每个结论都具有一定的置信度;并且在其间加入反馈机制,并通过其中的参数来控制反馈学习效率.

#### 3.1 嵌入模糊逻辑

在改进学习中,对于上下文数据,先需要进行模糊化表示,使每一条上下文对应一组语义值与真实度对,即 (linguistic value, membership degree), 其真实度的获得可以通过一组对应真实度函数关系取得,即  $(f_1(\gamma_1, x), f_2(\gamma_2, x), \dots, f_n(\gamma_n, x))$ , 其中  $n$  表示语义值的维数,  $\gamma_i, i=1,2,\dots,n$ , 是真实度函数参数.例如对于温度,如果高于  $30^\circ\text{C}$ , 我们会觉得很热,如果是  $20^\circ\text{C}$  左右,我们会觉得温度适中,如果低于  $10^\circ\text{C}$  我们就会觉得冷了,但如果是在  $25^\circ\text{C}$  左右或  $15^\circ\text{C}$  左右,那么对其冷热度的感观将要视不同的人 and 不同的场景而定了.在此我们将每一条温度信息表示为一个真实度(高,中,低)组,假设其隶属度函数如公式(7)所示,初始  $\gamma_1 = \gamma_2 = \gamma_3 = 5$  时,对于温度  $28^\circ\text{C}$ , 相对于“高”的真实度为 0.923 0, 相对于“中”的真实度为 0.2780, 相对于“低”的真实度为 0.001 5.

$$f_{high}(\gamma_1, x) = \begin{cases} 1, & x > 30 \\ e^{\frac{1}{2} \left( \frac{x-30}{\gamma_1} \right)^2}, & x \leq 30 \end{cases}; f_{middle}(\gamma_2, x) = e^{\frac{1}{2} \left( \frac{x-20}{\gamma_2} \right)^2}, 10 < x < 30; f_{high}(\gamma_3, x) = \begin{cases} e^{\frac{1}{2} \left( \frac{x-10}{\gamma_3} \right)^2}, & x \geq 10 \\ 1, & x < 10 \end{cases} \quad (7)$$

由公式(4)~公式(6)可知,神经网络的反向传播学习,是根据误差代价函数  $E$  与影响结果网络路径来进行自适应学习的,因此将引入到真实度函数参数  $\gamma_i, i=1,2,\dots,n$ ,  $n$  表示所模糊化成的语义值的维数,其值学习如公式(6)所示,其中  $i=1,2,\dots,n$ .

$$\frac{\partial E}{\partial \gamma_i} = \frac{\partial E}{\partial(\alpha^{(n)}(p_j))} \frac{\partial(\alpha^{(n)}(p_j))}{\partial(\alpha^{(n-1)}(p_j))} \dots \frac{\partial(\alpha^{(1)}(p_j))}{\partial \gamma_i}; \quad \gamma_i(k+1) = \gamma_i(k) - \eta \frac{\partial E}{\partial \gamma_i} \quad (8)$$

为了更简便地表示梯度,设  $x_{ji}, W_{ji}$  分别为单元  $j$  的第  $i$  输入和权值,  $NET_j = \sum_i x_{ji} W_{ji}$ , 即单元  $j$  引燃后的输出结果,  $\alpha_j, \alpha_j^{(1)}$  分别为单元  $j$  计算出的输出和理想输出.对于输出单元和隐藏单元,分别可导出公式(9)和公式(10),其中 Downstream 是为库所  $j$  所有直接下游单元的集合<sup>[15]</sup>.

$$\frac{\partial E}{\partial W_{ji}} = \alpha_j (1 - \alpha_j) (\alpha_j - \alpha_j^{(1)}) x_{ji} \quad (9)$$

$$\frac{\partial E}{\partial W_{ji}} = \alpha_j (1 - \alpha_j) \left( \sum_{k \in \text{Down}} \alpha_k (1 - \alpha_k) (\alpha_k - \alpha_k^{(1)}) x_{ji} \right) \quad (10)$$

因此,系统在训练集上,据公式(6)和公式(8),不断反复学习,直到误差在接受标准范围内即可.

#### 3.2 反馈学习

在推荐系统经自适应学习后,在其运行过程中,进行反馈学习,这样使系统更能适应复杂多变的环境和满足不同偏好推理的人.

据由公式(3)给出的误差代价函数为  $E$ , 并由此函数对参数求偏导得出梯度  $\left\{ \frac{\partial E}{\partial W_1}, \frac{\partial E}{\partial W_2}, \dots, \frac{\partial E}{\partial W_n} \right\}$ ,

$\left. \frac{\partial E}{\partial \gamma_1}, \frac{\partial E}{\partial \gamma_2}, \dots, \frac{\partial E}{\partial \gamma_m} \right\}$  其中  $n$  为权值数,  $m$  为隶属度函数维数, 在复平面中, 该梯度方向的反方向, 就为  $E$  减小最快的方向. 由公式(9)和公式(10)可知, 每次对一组上下文, 经推理系统推理后, 如果结果不符合需要, 据公式(11)进行反向传播, 其中  $\eta^{(1)}$  是反馈学习效率, 用以区分训练学习效率, 并且可以用  $\eta$  和  $\eta^{(1)}$  不同, 来控制先验与后验对系统的影响.

$$W_{ji}(k+1) = W_{ji}(k) - \eta^{(1)} \frac{\partial E}{\partial W_{ij}^{(q)}}; \quad \gamma_i(k+1) = \gamma_i(k) - \eta^{(1)} \frac{\partial E}{\partial \gamma_i} \quad (11)$$

### 3.3 推理过程

FAFPN 的整个推理过程总结如下:

(1) 模糊化. 根据模糊隶属度函数将每条上下文数据变成一组带真实度的语义值, 这些带真实度的语义值就是 PN 的输入, 即图 1 中的  $\alpha(A), \alpha(B), \alpha(C)$ ;

(2) 初始化. 根据先验知识设定初始参数, 对于变迁阈值  $Th = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$ , 可以用来控制并行推理的规模, 阈值越小, 并行推理规模越大, 阈值越大, 规模越小, 对于学习效率  $\eta$ , 是用来控制模型的收敛速率的, 但如果  $\eta$  过大, 训练过程将可能不收敛<sup>[15]</sup>, 对于错误接受标准  $\varepsilon$ , 是系统结束的条件;

(3) 训练. 根据推理规则, 对于所有的单元, 如果  $\sum_{j=1}^n \alpha(P_j) \cdot W_{ij} \geq Th(t)$ , 引燃单元并根据公式(2)推出结果, 如果输出结果偏离理想结果, 根据调整误差代价函数  $E$  和 BP 算法, 调整参数, 直到误差代价函数  $E < \varepsilon$ ;

(4) 应用. 经过上面的(3)后, 将得到一个与训练集拟合的模型, 如果在应用过程中, 推理结果不理想, 就加入反馈机制, 利用公式(11)和  $\eta^{(1)}$  进一步根据调整参数.

## 4 实验和测试分析

为了验证 FAFPN 的学习效率, 我们设计了一个情境感知系统——会议环境推荐系统 (conference environment recommendation system, 简称 CERS). 人们都追求更加舒适、智能的普适环境, CERS 正是根据会议室内的上下文信息, 如温度、湿度、亮度、与会人数、主持人喜好等等, 推荐服务的, 如调节空调、调节加湿器、控制灯的开关或调节灯的明暗、控制投影仪和推荐展示工具等.

### 4.1 实验环境

由于 CERS 涉及的规则和库所数很多, 网络层次复杂, 为了描述更加方便, 在实验分析中, 仅截取其中相对独立的 18 条规则, 共 36 个库所进行说明.

$$f_{humidity} = \begin{cases} f_{high}(\gamma_4, x) = \begin{cases} 1, & x > 70 \\ e^{\frac{1}{2}(\frac{x-70}{\gamma_4})^2}, & x \leq 70 \end{cases} \\ f_{middle}(\gamma_5, x) = e^{\frac{1}{2}(\frac{x-40}{\gamma_5})^2}, & 10 < x < 70, \\ f_{high}(\gamma_6, x) = \begin{cases} e^{\frac{1}{2}(\frac{x-10}{\gamma_6})^2}, & x \geq 10 \\ 1, & x < 10 \end{cases} \end{cases} \quad f_{number} = \begin{cases} f_{high}(\gamma_7, x) = \begin{cases} 1, & x > 0.6 \\ e^{\frac{1}{2}(\frac{x-0.6}{\gamma_7})^2}, & x \leq 0.6 \end{cases} \\ f_{middle}(\gamma_8, x) = e^{\frac{1}{2}(\frac{x-0.4}{\gamma_8})^2}, & 0.2 < x < 0.6 \\ f_{high}(\gamma_9, x) = \begin{cases} e^{\frac{1}{2}(\frac{x-0.2}{\gamma_9})^2}, & x \geq 0.2 \\ 1, & x < 0.2 \end{cases} \end{cases} \quad (12)$$

嵌入模糊逻辑时, 采用公式(7)和公式(12)所示的隶属度函数组分别对温度、湿度和人数进行模糊化, 而系统是基于模糊产生式规则进行推理的, 产生式规则见表 2, 其中  $R1$  表示会议室温度,  $R2$  表示会议室空气的相对湿度,  $R3$  表示与会人数,  $R4$  表示对空调的调节, 其转化为 FAFPN 如图 2 所示. 在图 2 中,  $AFP_N = \{P, T, D, I, O, \alpha, \beta, Th, W\}$ , 其中  $P = \{P_{1,1}, P_{2,1}, \dots, P_{18,1}, P_{1,2}, P_{2,2}, \dots, P_{18,2}, P_{10,3}, P_{11,3}, \dots, P_{18,3}\}$ ,  $T = \{t_1, t_2, \dots, t_{18}\}$ ,  $Th = \{\lambda_1, \lambda_2, \dots, \lambda_{18}\}$ ,  $W_o = \{\mu_1, \mu_2, \dots, \mu_{18}\}$ ,  $W_t = \{W_{1,1}, W_{2,1}, \dots, W_{18,1}, W_{1,2}, W_{2,2}, \dots, W_{18,2}\}$ . 对于每一组上下文数据, 经模糊化后将对应数条规则, 相应将推理得到多个结果, 最后采用取最大真实度原则推荐结果, 即取真实度最大的结论作为结果.

Table 2 The fuzzy inference rules

表 2 模糊产生式规则

1. If  $R1$  is "High" and  $R2$  is "High", then  $R3$  is "High";
2. If  $R1$  is "High" and  $R2$  is "Medium", then  $R3$  is "High";
3. If  $R1$  is "High" and  $R2$  is "Low", then  $R3$  is "Medium";
4. If  $R1$  is "Medium" and  $R2$  is "High", then  $R3$  is "High";
5. If  $R1$  is "Medium" and  $R2$  is "Medium", then  $R3$  is "Medium";
6. If  $R1$  is "Medium" and  $R2$  is "Low", then  $R3$  is "Few";
- ...
- ...
16. If  $R3$  is "Low" and  $R4$  is "Many", then  $R4$  is "Keep";
17. If  $R3$  is "Low" and  $R4$  is "Medium", then  $R4$  is "Up";
18. If  $R3$  is "Low" and  $R4$  is "Few", then  $R4$  is "Up";

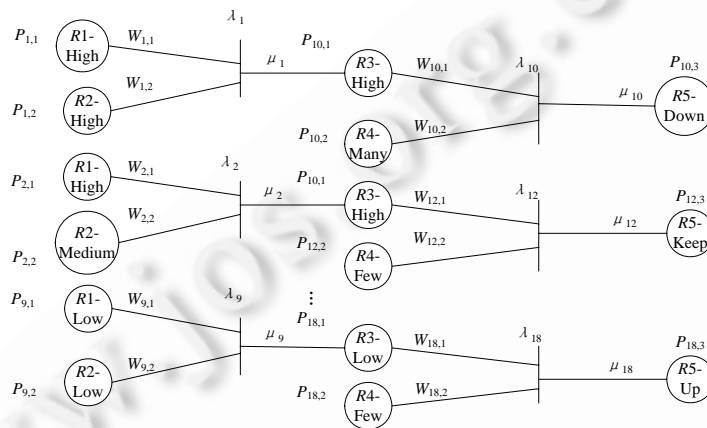


Fig.2 The Petri net of CERS

图 2 CERS 的 Petri 网模型图

4.2 模拟分析

在本节的模拟分析实验中,训练集的理想结果是在预先设定的参数值的基础上得到的,因而在整个推理和参数迭代的过程中,参数应向预先设定的值逼近.

预先设定  $W_{i,1} = 0.6, W_{i,2} = 0.4, 0 < i < 10; W_{j,1} = 0.8, W_{j,2} = 0.2, 9 < j < 19$ . 在 250 个训练集上,随着迭代次数的增加,AFPN 和 FAFPN 的权值学习图分别如图 3 和图 4 所示.可以清晰地看到,所有权值都渐近于预设值,而且 FAFPN 的渐近速度要远大于 AFPN 的渐近速度,即在 FAFPN 中,经过 200 次迭代,权值基本接近预设值,而在 AFPN 中要到 350 次左右.




Fig.3 Weight learning process by AFPN  
图 3 AFPN 的权值学习过程图




Fig.4 Weight learning process by improved learning on AFPN  
图 4 FAFPN 的权值学习过程图

### 4.3 实验分析

在测试分析中,训练集与测试集中的理想结果是由统计的方法得到的,即在相同的上下文条件下,统计不同人对服务的满意情况,如在(温度,相对湿度,人数)=(26°C,0.35,37)时,统计每个人的感觉,如果其中认为空调调高的人数为  $a$ ,不调的人数为  $b$ ,调低的人数为  $c$ ,则其理想的服务推荐应是调高、不调和调低的真实度分别为  $\frac{a}{a+b+c} \times 100\%$ ,  $\frac{b}{a+b+c} \times 100\%$  和  $\frac{c}{a+b+c} \times 100\%$ . 因此服务推荐系统经反复学习后,也应尽量逼近此结果.

实验中,我们在 500 个样本数据上进行测试和训练,其中训练数据 250 个,测试数据 250 个,并假定参数值为所有  $W=0.5, \lambda=0.01$ ,学习效率  $\eta$  为 0.05,反馈效率  $\eta^{(1)}$  为 0.005,其中  $W$  可任意假定,因为通过反复训练,都会渐近理想值; $\lambda$  的设置,可以用来控制 PN 的并发的规模,因为实验中截的规则并不太多,所以设置的  $\lambda$  较小; $\eta$  和  $\eta^{(1)}$  是由经验得来的. 在 1000 次学习之后,不断学习参数  $W$  和  $\gamma$ ,所训练出的模型,在训练集和测试集上的拟合结果如图 5 所示. 由图 5 可以明显地看出,模型经过反复学习之后,在测试集和测试集上的错误数明显减小,并趋近于稳定,由从第 800 到第 1000 次的训练结果中可以看出,在训练集、不带反馈的测试集和带反馈的测试集上,错误率均值分别为 0.80%, 3.16% 和 1.28%,方差为 0.0013 和 0.0017. 而且当加入反馈后,在测试集上的结果也要比未加反馈的结果好很多,错误率从 3.12% 降到了 1.20%.




Fig.5 Experiment result  
图 5 实验结果统计图

## 5 结束语

本文应用 AFPN,模糊逻辑原理,提出了 FAFPN,即在 AFPN 中加入反馈机制的自适应学习方法,并对此方法进行了数学推导和实验验证,还有将模糊逻辑理论引入对上下文的描述,使其更能符合人们的认识.

下一步将在模糊逻辑的上下文感知系统架构(FLECA)<sup>[16]</sup>中应用此学习方法,使其能够更好地推荐个性化服务.

**致谢** 在此,我们向对本文的工作给予支持和建议的老师和同学,尤其是计算技术研究所普适计算研究中心的朱珍民教授和叶剑博士表示感谢.

### References:

- [1] Dey AK. Understanding and using context. *Personal and Ubiquitous Computing*, 2001,5(1):4-7.
- [2] Henriksen K, Indulska J. Modelling and using imperfect context information. In: *Proc. of the 2nd Annual Conf. on Pervasive Computing and Communications*. Washington: IEEE Computer Society Press, 2004. 33-37.
- [3] Riva G, Vatalaro F, Davide F, Alcañiz M. Interactive context-aware systems interacting with ambient intelligence. In: Riva G, Vatalaro F, eds. *Ambient Intelligence*. IOS Press, 2005. 160-178.
- [4] W3C Web-Ontology (Web-Onto) Working Group. <http://www.w3.org/2001/sw/WebOnt/>

- [5] Karvounarakis G, Alexaki S, Christophides V, Plexousakis D, Scholl M. RQL: A declarative query language for RDF. In: Lassner D, Roure D, eds. Proc. of the 11th Int'l World Wide Web Conf. New York: ACM Press, 2002. 592–603.
- [6] Bikakis A, Patkos T, Antoniou G, Plexousakis D. A survey of semantics-based approaches for context reasoning in ambient intelligence. In: Muhlhauser M, Ferscha A, eds. Constructing Ambient Intelligence 2007 Workshop, Communications in Computer and Information Science. 2008. 14–23.
- [7] Krummenacher R, Kopecký J, Strang T. Sharing context information in semantic spaces. Lecture Notes in Computer Science, 2005. 229–232.
- [8] Gu T, Pung HK, Zhang DQ. A middleware for building context-aware mobile services. In: Proc. of the IEEE Vehicular Technology Conf. Milan: IEEE Computer Society Press, 2004,5(1):2656–2660.
- [9] Wang XH, Dong JS, Chin CY, Hettiarachchi SR, Zhang DQ. Semantic space: An infrastructure for smart spaces. IEEE Pervasive Computing, 2004,3(3):32–39.
- [10] Ranganathan A, Campbell RH. An infrastructure for context-awareness based on first order logic. Personal Ubiquitous Computing, 2003,7(6):353–364.
- [11] Chen S, Ke J, Chang J. Knowledge representation using fuzzy Petri nets. IEEE Trans. on Knowledge and Data Engineering, 1990, 2(3):311–319.
- [12] Yu ZW, Lin N, Nakamura Y, Kajita S, Mase K. Fuzzy recommendation towards QoS-aware pervasive learning. In: Proc. of the 21st Int'l Conf. on Advanced Networking and Applications. Washington: IEEE Computer Society Press, 2007. 604–610.
- [13] Li X, Rosano FL. Adaptive fuzzy Petri nets for dynamic knowledge representation and inference. Expert Systems with Applications, 2000,19(3):235–241.

#### 附中文参考文献:

- [14] 鲍培明. 基于 BP 网络的模糊 Petri 网的学习能力. 计算机学报, 2004, 27(5).
- [15] Mitchell TM, 著; 曾华军, 张银奎, 译. 机器学习. 第 4 版, 北京: 机械工业出版社, 2006. 60–94.
- [16] 高晓芳, 叶剑, 朱珍民, 刘金刚. 嵌入模糊逻辑的上下文存储与查询机制. 见: 第 5 届全国普适计算学术会议. 2009.



文赛平(1986—), 男, 湖南益阳人, 硕士生, 主要研究领域为普适计算.



叶剑(1974—), 男, 博士, 高级工程师, 主要研究领域为普适计算, 情境感知.



朱珍民(1962—), 男, 博士, 高级工程师, 主要研究为普适计算, 嵌入式系统, 服务计算.