

## ART2wNF 及其稳定性— 可塑性动态平衡性能分析

陈众<sup>1</sup> 莫红<sup>1</sup>

**摘要** 稳定性—可塑性两难问题的核心是系统如何在不削弱或忘记已学习模式的同时, 自适应地学习新事物. 目前公认自适应谐振理论 (Adaptive resonance theory, ART) 能够部分解决稳定性—可塑性两难问题, 但依然存在学习受样本输入顺序影响大, 且存在学习中心渐变样本时, 带来的所谓模式漂移的问题. 受进化生物学关于人类学习的幼态延续特征的启发, 本文为每个  $F_2$  层节点配备活跃度指示器  $\lambda$ , 并将其反馈回  $F_1$  层参与 STM (Short term memory) 向量的计算, 使这种新型 ART2 网络在行为特征上具备幼态延续的显著特征, 本文称之为 ART2wNF (Adaptive resonance theory with neoteny feature). 论文从理论上证明算法的可行性, 并通过分析对随机生成样本集合的学习过程, 对比了 ART2wNF 算法与常规 ART2 网络在可塑性、稳定性方面的差异以及 ART2wNF 在克服样本输入顺序影响等方面的优势.

**关键词** 稳定性—可塑性两难问题, 幼态延续, 自适应谐振理论, ART2 网络, ART2wNF

**引用格式** 陈众, 莫红. ART2wNF 及其稳定性—可塑性动态平衡性能分析. 自动化学报, 2013, 39(8): 1381—1388

**DOI** 10.3724/SP.J.1004.2013.01381

### ART2wNF and Its Stability-plasticity Dynamic Trade-off Analysis

CHEN Zhong<sup>1</sup> MO Hong<sup>1</sup>

**Abstract** Stability-plasticity dilemma is how to build a system that is adaptive enough to learn new things while not diluting/forgetting previously learned patterns. It is well known that ART (adaptive resonance theory) network can partially solve the stability-plasticity dilemma, but the behavior of ART network is uncertain due to the input order of samples and the pattern drift problem which is also notable for patterns with gradually changed center. Inspired by the human neoteny phenomenon discussed in evolution biology, in order to record the stimulating degree, we suggest that each node in  $F_2$  layer be accompanied by an activity indicator  $\lambda$ , which is also fed back to  $F_1$  layer as a parameter of the calculation of STM (short term memory) vectors. The modified ART2 network has the remarkable feature of neoteny during learning process and is called ART2wNF (adaptive resonance theory with neoteny feature) in this paper. The feasibility of the arithmetic is theoretically proved for the introduction of  $\lambda$  at first. Then the performance and distinctness of ART2wNF in stability and plasticity are compared with ART2 by analyzing the learning process for randomly generated samples. It also shows the distinctive ability to overcome the shortage of ART2 caused by different input orders.

**Key words** Stability-plasticity dilemma, neoteny, adaptive resonance theory (ART), ART2 network, ART2wNF

**Citation** Chen Zhong, Mo Hong. ART2wNF and its stability-plasticity dynamic trade-off analysis. *Acta Automatica Sinica*, 2013, 39(8): 1381—1388

## 1 引言

### 1.1 稳定性—可塑性两难问题

竞争学习网络学习得到的类别通常很难保持稳定, 一个定型的类别仍然可能由于新样本的影响不断地发生变化<sup>[1]</sup>. 为了稳定学习过程, 就必须将学习率设置得很小, 但这又会使网络难以学习新的模式, 从而失去了可塑性, 这就是“稳定性—可塑性”两难问题 (Stability-plasticity dilemma). 简单地讲, 稳定性—可塑性两难问题就是系统如何在学习新事物的同时尽可能地保持原有的记忆. 在模式聚类研究领域, 通常认为这个概念是由 Carpenter 等在自适应谐振理论 (Adaptive resonance theory, ART) 的研究中提出的<sup>[2]</sup>. 自适应谐振网络的带反馈的两层结构使其能够部分地解决稳定性—可塑性两难问题, 目前已发展出多种不同类型网络形式<sup>[2-6]</sup>. 在 ART 网络中, 所谓稳定性 (Stability) 是指经学习产生的编码具备稳定性, 避免系统不停地进行编码操作. 而可塑性 (Plasticity) 则是系统依据一系列的环境输入自适应地进行认识编码 (Recognition codes), 在学习的过程中, 输入和系统的交互作用产生新的稳定状态或吸引区域<sup>[2-3]</sup>. 一个成熟的 ART 系统必须能够在两种模式之间自适应地切换<sup>[2]</sup>: 它必须具备可塑性以学习系统所面临的有意义的变化, 同时对于不相干的或重复出现的变化要能保持稳定. 目前普遍认为 ART2 网络能够部分解决稳定性—可塑性两难问题, 主要体现在以下两个方面:

1) 包括匹配—重置机制的两层结构体系使得对当前活跃节点的 LTM (Long term memory) 向量修正不会影响其他节点, 但前提是网络能够正确聚类, 不恰当的参数设置会影响聚类结果, 从而对编码过程带来影响.

2) 稳定性—可塑性切换:  $F_2$  层节点在定型前保持高可塑性, 在定型后的慢速再编码阶段则以保持稳定为主. 因此, 目前的切换能力并不强, 仅仅体现在定型前后.

一般来说, 为了抑制噪声的影响, ART2 网络需要保持稳定; 而为了克服样本输入次序对分类结果的影响, 则需要具有一定的可塑性. 但 ART2 的稳定性—可塑性平衡点 (Stability-plasticity trade-off) 是由其网络参数所决定的, 不具备可调整性. 近十年来, 国内对 ART2 网络的研究也主要集中在应用领域, 也有部分算法改进或结构改进方面的研究<sup>[7-11]</sup>, 但都使用固定的网络参数, 因此, 在聚类过程中是不具备稳定性—可塑性自适应切换能力的. 此外, 许多文献包括 Carpenter 的论文中都提到 ART2 网络聚类结果会受到样本输入顺序影响, 本文研究认为恰当的稳定性—可塑性平衡点切换, 即可削弱样本输入顺序的影响.

### 1.2 幼态延续特性

进化生物学的研究表明人类的婴儿比其他灵长目动物的

Supported by National Natural Science Foundation of China (61074903, 61233088), Open Project of State Key Laboratory of Management and Control for Complex Systems, Institute of Automation, Chinese Academy of Science, and Youth Talent Support Plan of Changsha University of Science and Technology

本文责任编辑 王聪

Recommended by Associate Editor WANG Cong

1. 长沙理工大学电气与信息工程学院 长沙 410004

1. School of Electric and Information Engineering, Changsha University of Science and Technology, Changsha 410004

收稿日期 2012-06-27 录用日期 2013-03-04  
Manuscript received June 27, 2012; accepted March 4, 2013  
国家自然科学基金 (61074903, 61233088), 中国科学院自动化研究所复杂系统管理与控制国家重点实验室开放课题, 长沙理工大学青年英才计划资助

幼体需要更多的照料和更长时间的发育才能达到成熟,例如大猩猩两岁即可独立外出觅食,3~4岁即离开母亲独自活动,但显然人类做不到。人类在其他生理机能(例如性)接近成熟时,大脑的发育和心智的成长仍在持续,研究者们引入了“幼态延续”(Neoteny)的概念来解释这种现象<sup>[12]</sup>。

幼态延续是指在成年期保持孩童时代特征的趋向,它是人类进化的显著特点,它使人能够长期保持好奇心,为进化过程中机体的新变化提供了时间和机会,以应对人类社会的复杂性。对照稳定性-可塑性两难问题,也可以认为幼态延续特性使智人在相当长的成长期内保持较强可塑性,以便于更好地形成复杂的知识概念,甚至直到成年期,依然保留一定可塑性。

举例而言,门外来了只乌龟,小孩会跑出去看,而成年人则选择坐着不动,但如果门外有只两个头的乌龟,则大人小孩全都会跑出去看。因此,我们说儿童可塑性强,稳定性弱,成年人可塑性弱,稳定性强。但对陌生的事物,成年人也会表现出较强的学习兴趣,保持与儿童相当的可塑性水平。综上所述,我们可以得到两个与“稳定性-可塑性平衡”有关的事实:

- 1) 随时间推移,在智力发展的初期与后期,学习主体的稳定性-可塑性平衡点是不同的;
- 2) 同一时刻,主体为两个不同类别建立的概念可以处于不同的稳定性-可塑性平衡点。

我们将这种特性称之为“多点动态平衡”,“动态”是指对同一事物,随熟悉程度的加深,平衡点会发生改变,而“多点”则是指在同一时刻,根据学习主体对不同类别事物的熟悉程度不同,对应的可塑性-稳定性平衡点可以处在不同位置。

### 1.3 本文工作

本文作者在前期研究中使用 ART2 网络模拟了皮亚杰图式理论中的“同化”、“顺应”等基本心理学过程,并在图像处理等方面给出了一些应用实例<sup>[13-15]</sup>,并认为 ART2 网络具备了实现多点动态平衡的基本条件。根据幼态延续的概念,我们来设想解决稳定性-可塑性两难问题的最好效果:

- 1) 在刚开始学习一类样本时,网络保持较强的可塑性,单个样本不会对 LTM 向量的定型产生决定性的作用;
- 2) 在连续输入一定数量的样本,找到样本的聚类中心后,学习该类别的样本越多,稳定性越强, LTM 向量越不容易被单个奇异样本的干扰。

为此,本文提出了具有幼态延续特性的 ART2 网络(ART2 with neoteny feature, ART2wNF)。它能够在学习的初级阶段保持较强的可塑性,随着网络对某一模式逐渐熟悉,可塑性减弱,稳定性逐渐加强。聚类后得出的不同类别在同一时刻可以处于不同的稳定性-可塑性平衡位置,有利于区别对待熟悉程度不同的类别,合理地、有区别地进行学习。这种学习方式整体上表现为“多点动态平衡”的特性,抗干扰能力比 ART2 有明显提高,可有效克服样本输入次序对聚类结果带来的不良影响。

## 2 ART2 网络

### 2.1 结构

ART2 网络的典型结构如图 1(a) 所示,其中,空心圆点表示求和运算,实心圆点表示求模运算。图 1 中沿用文献[2]使用标量(例如  $I_i$ )表示运算关系,输入向量应表示为  $\mathbf{I}$ ,  $\mathbf{w}$ 、 $\mathbf{x}$ 、 $\mathbf{v}$ 、 $\mathbf{u}$ 、 $\mathbf{q}$  和  $\mathbf{p}$  为短期记忆(Short-term memory, STM)向量,  $\mathbf{z}_{iJ}$  和  $\mathbf{z}_{Ji}$  分别代表当前激活节点  $J$  的  $F_1$  层到  $F_2$  层

和  $F_2$  层到  $F_1$  层的连接权重分量,它们的初始值不相同。 $F_2$  层的第  $J$  个节点被定型后,有  $\mathbf{z}_{Ji} = \mathbf{z}'_{iJ}$  为长期记忆系统(Long-term memory, LTM)向量,在不引起歧义的情况下,本文中简记为  $\mathbf{z}_J$ 。

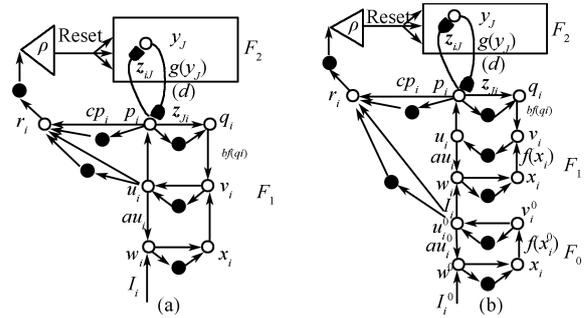


图 1 ART2 网络典型结构

Fig. 1 Typical Structures of ART2 network

图 1 中, STM 向量  $\mathbf{p}$  可视为 LTM 向量  $\mathbf{z}_J$  (“回忆”模式)与输入向量  $\mathbf{I}$  的组合,网络通过向量  $\mathbf{r}$  监视  $\mathbf{I}$  与  $\mathbf{p}$  的匹配程度,与系统警戒值比较,从而判断系统  $F_2$  层当前“回忆”结果是否正确。其调整原则(学习规则)是网络性能的关键。函数  $f$ 、 $g$ 、参数  $a$ 、 $b$ 、 $c$ 、 $d$  的含义以及系统的运行原理见文献[3-4]。

图 1(b) 中的网络相对图 1(a) 增加了一个  $F_0$  的预处理层,结构与  $F_1$  中的低层和高层圈相似。除了输入向量  $\mathbf{I}$  是预处理层的输出向量外,这样的结构允许  $\mathbf{I}$  自己作为调整子系统的输入,而非图 1(a) 中的向量  $\mathbf{u}$ 。这样做的优势在于当  $F_1$  活跃时,  $\mathbf{I}$  不变,因此,在试验中  $\mathbf{I}$  向调整子系统提供了比  $\mathbf{u}$  更稳定的输入。

### 2.2 ART2 学习规则

#### 2.2.1 慢速学习

文献[3]中明确给出,当  $F_2$  层第  $J$  个节点被激活,对应的 LTM 向量  $\mathbf{z}_J$  的学习规则表达为

$$\frac{d\mathbf{z}_J}{dt} = d(1-d) \left[ \frac{\mathbf{u}}{1-d} - \mathbf{z}_J \right] \quad (1)$$

图 1 中,当  $F_2$  层激活第  $J$  个节点,  $g(y_j) = d$ , 其他的节点  $g(y_j) = 0$ , 且  $0 < d < 1$ <sup>[3]</sup>。由式(1)可知,与其他神经网络相比, ART2 网络的显著特点之一就是它是一种连续网络<sup>[8]</sup>。将式(1)离散化,可以得到离散形式的慢速学习(Slow learning)规则:

$$\mathbf{z}_J(t + \Delta t) = \Delta t d \mathbf{u} + (1 - \Delta t d (1 - d)) \mathbf{z}_J(t) \quad (2)$$

许多文献使用了符号  $\alpha$  取代  $\Delta t$ , 并明确地称  $\alpha$  为学习速率(Learning rate)。慢速学习规则具有保留 LTM 向量  $\mathbf{z}_J$  原有值的趋向,这种特性称之为慢速再编码(Slow recoding)。再编码的速率在连续网络中取决于样本呈现的时间,在离散网络中则取决于学习速率。

#### 2.2.2 快速学习

当输入样本持续的时间足够长,即时间  $t \rightarrow \infty$ , 等价于令式(1)等于 0, 可得:

$$\mathbf{z}_J = \frac{\mathbf{u}}{1-d} \quad (3)$$

即众多 ART2 研究文献通常采用快速学习 (Fast learning) 规则<sup>[8]</sup>. 如果图 1 中的函数  $f(\cdot)$  为线性函数, 由文献 [4], 可以证明在采用快速学习条件下, LTM 向量  $\mathbf{z}_J$  与  $F_1$  层的中间向量  $\mathbf{u}$  方向相同. 快速学习的显著特征是 LTM 向量  $\mathbf{z}_J$  的幅值一次性达到  $1/(1-d)$ , 称之为快速定型特性 (Fast commitment).

但需要说明的是由于 STM 向量  $\mathbf{u}$  的迭代计算中用到了  $F_2$  层的 LTM 反馈, 因此, 快速学习规则也具有使 LTM 向量  $\mathbf{z}_J$  保持原有存储信息的能力. 在后续章节中, 我们将说明这种保持能力取决于 ART2 的网络参数.

### 2.2.3 ART2-A 的折中学习

在实际应用中, ART2 网络经常需要有一个合适的学习速率来应对噪声和保持系统稳定性, 同时克服样本输入次序对分类结果的影响. 文献 [4] 指出, 相对过激的快速学习方式不适合处理噪声水平较高的数据集, 而慢速学习虽然可以较好地处理噪声问题, 但可能存在无意义的搜索过程, 导致计算速度慢. 为此, 基于图 1 (b) 结构 ( $F_1$  层阈值  $\theta = 0$ ), 文献 [4] 提出了 ART2 网络的折中学习 (Intermediate learning) 概念, 并称之为 ART2-A 算法.

令  $\mathbf{z}_J^*$  表示一个比例缩放后 LTM 向量,  $\mathbf{z}_J^* = (1-d)\mathbf{z}_J$ , 则式 (1) 慢速学习修正为

$$\frac{d\mathbf{z}_J^*}{dt} = d(1-d)(\mathbf{u} - \mathbf{z}_J^*) \quad (4)$$

根据式 (4),  $\mathbf{z}_J^*$  以固定的速度接近  $\mathbf{u}$ . 当  $J$  为非定型节点时, 在整个输入提交期间,  $\mathbf{u}$  恒等于  $\mathbf{I}$ , 因此, 向量  $\mathbf{z}_J^*$  以指数级速度接近  $\mathbf{I}$ . 如果相对  $1/(1-d)$ , 输入提交的时间间隔长度很长, 那么最后将满足  $\mathbf{z}_J^* \approx \mathbf{I}^{[4]}$  (针对模拟形式网络而言). 另一方面, 文献 [4] 已经证明, 在图 1 (b) 结构中向量  $\mathbf{u}$  满足:

$$\mathbf{u} = \mathfrak{N}(\varepsilon\mathfrak{N}\Psi + (1-\varepsilon)\mathbf{z}_J^*) \quad (5)$$

其中,  $\mathfrak{N}$  为归一化操作. 从而有:

$$\frac{d\mathbf{z}_J^*}{dt} \approx \varepsilon d(1-d)(\mathfrak{N}\Psi - \mathbf{z}_J^*) \quad (6)$$

如果  $J$  为定型节点, 由于  $\varepsilon$  的因素,  $\mathbf{z}_J^*$  接近  $\mathfrak{N}\Psi$  的速度比未定型节点的速度慢. 显然较小的  $\varepsilon$  可以使得向量  $\mathbf{u}$  更靠近向量  $(1-d)\mathbf{z}_J$ , 削弱了新输入向量的影响, 系统的稳定性得到加强. 在数字仿真计算中, 文献 [4] 将上述过程简化, 制定了 ART2-A 的折中学习:

$$\mathbf{z}_J^{*(new)} = \begin{cases} \mathbf{I}, & \text{若 } J \text{ 为未定型节点} \\ \mathfrak{N}(\beta\mathfrak{N}\Psi + (1-\beta)\mathbf{z}_J^{*(old)}), & \text{若 } J \text{ 为定型节点} \end{cases} \quad (7)$$

$$\text{其中, } \Psi_i = \begin{cases} I_i, & \text{若 } \mathbf{z}_{J_i}^{*(old)} > \theta \\ 0, & \text{否则} \end{cases}, \text{ 且 } 0 \leq \beta \leq 1.$$

如果  $J$  是一个定型节点,  $\mathbf{z}_J^{*(old)}$  指的是  $\mathbf{z}_J^*$  在输入开始提交时的值,  $\mathbf{z}_J^{*(new)}$  是更新后的值. 需要说明的是快速定型特性是指在激活了未定型 (Uncommitted) 节点时, 采用快速学习, 使 LTM 向量的模  $\|\mathbf{z}_J\|$  一次达到  $1/(1-d)$ . 慢速再编码特性则是在激活了已定型 (Committed) 节点时, 采用近似慢速学习的学习规则, 解决噪声和样本输入顺序带来的影响. 折中学习的主要行为特征是同时具备快速定型特性和慢速再

编码特性, 但不能被视为是介于快速学习与慢速学习的中速学习, 而是快速学习和慢速学习的结合体. 虽然折中算法只能适用于图 1 (b) 结构的 ART2-A, 但其推导过程能够带给我们一些启示, 在下文中我们将继续进行讨论并加以利用.

## 3 具有幼态延续特征的 ART2wNF

具有代表性的 BP 网络, 从其结构特征来看, 整个网络是一个密不可分的整体. 假定在权值调整结束后, 已经能够正确分类已学习类别, 而此时如果有新的类别加入, 则需要再次学习所有样本, 并重新调整全部的权值. 由于原有网络权值会被修改, 显然 BP 网络不具备实现多点动态平衡的基本能力. 对比之下, ART 系列网络与生物神经系统比较接近, 记忆模式也与生物的记忆形式类似. ART 模型的短期记忆系统 (STM) 和长期记忆系统 (LTM) 的概念在认知发展论的图式理论中也有对应的概念以及功能描述<sup>[16-17]</sup>. 在前期的工作中, 我们将幼态延续学习的概念引入 ART2<sup>[18]</sup>, 本文正式提出 ART2wNF 的基本构架和算法. 与 ART2-A 的折中学习不同, 这种改进方法适用于所有 ART2 网络的变形体.

### 3.1 $F_2$ 层节点活跃度模型

首先, 我们提出为每个  $F_2$  层节点配备活跃度  $\lambda$  ( $\lambda \in (0, 1]$ ),  $\lambda$  代表了该节点受到持续刺激的程度.  $\lambda = 0^+$  为初始状态 (通常取一个非常小正数即可), 表示该节点处于休眠状态,  $\lambda = 1$  表示该节点进入完全活跃状态. 在节点受到刺激时,  $\lambda$  上升, 反之则下降. 式 (8) 提供了一个相对简单的活跃度调节方法:

$$\lambda_{j+1} = \begin{cases} \lambda_j + (1-\lambda_j) \times \alpha, & \text{若 } j = J \\ \begin{cases} \lambda_j + (1-\lambda_j) \times \alpha/n_1, & \text{若 } \lambda_j > \lambda_m, \\ \lambda_j + (1-\lambda_j) \times \alpha/n_2, & \text{若 } \lambda_j \leq \lambda_m, \end{cases} & \text{若 } j \neq J \end{cases} \quad (8)$$

令  $\lambda_m = 0.6$ ,  $\alpha = 0.05$ ,  $n_1 = 100$ ,  $n_2 = 10$ , 活跃度变化曲线如图 2 所示 (下降曲线中, 初始值  $\lambda = 0.95$ ). 横轴坐标既可以理解为时间也可以理解为学习次数, 取决于该网络工作在连续模式还是离散模式.

本组参数使得对某类样本学习 18 次左右, 活跃度上升到  $\lambda_m = 0.6$  (可根据需要调整), 此后学习次数增多, 可以继续上升. 如果某类样本只是最初出现几次后就消失了, 记忆该类别的  $F_2$  层节点活跃度会按上升速率的 1/10 衰减, 但如果对一类样本学习次数足够多, 活跃度超过  $\lambda_m$ , 此时活跃度下降速率将下降到上升速率的 1/100. 这意味着刺激次数超过 18 次后, 衰减速度将大大减缓.

活跃度的设计在生物学和心理学都有一定的理论基础支持. 通过不断重复, 大脑中的化学信号系统会把一种反应结合蛋白 (CAMP-resporoe element binding protein, CREB) 推入神经元的核心<sup>[19]</sup>. 研究人员发现长期记忆能力较强的老鼠, 其大脑中所含有的 CREB 蛋白质经常保持活跃的状态<sup>[20]</sup>. 德国实验心理学家赫尔曼·艾宾浩斯也指出了记忆保持和诵读次数的关系: 诵读次数越多、时间越长, 则记忆保持越久<sup>[21]</sup>.

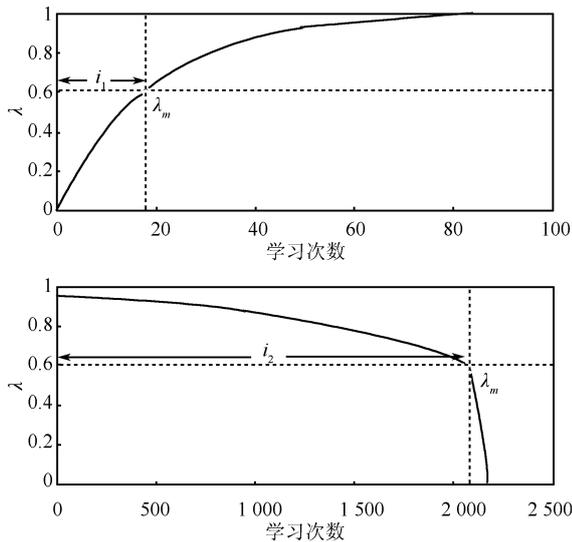


图2  $F_2$  层节点活跃度变化曲线  
Fig. 2 Trace of activities of  $F_2$  nodes

3.2 ART2wNF 结构

3.2.1 结构变化

文献 [4] 在证明折中学习算法过程中, 说明式 (6) 中  $\varepsilon$  的大小由参数  $a$  和  $b$  决定. 一般情况下, 参数  $a$  和  $b$  都被设置得足够大, 以获得一个较小的  $\varepsilon$  值, 从而削弱新输入向量的影响. 在常规 ART2 网络应用中, 参数  $a$  和  $b$  均恒定. 本文认为在不同的学习阶段新输入对 LTM 向量的影响应有所不同. 由进化生物学幼态延续学习的特征可知, 人的认知具备早期可塑性强、后期稳定性强的特征, 因此, 动态变化  $a$  和  $b$  的值能使得网络特性有所改变. 在图 1 ART2 网络结构的基础上, 本文将当前胜出节点的活跃度  $\lambda_J$  反馈回  $F_1$  层, 参与 STM 向量计算, 结构如图 3 所示.

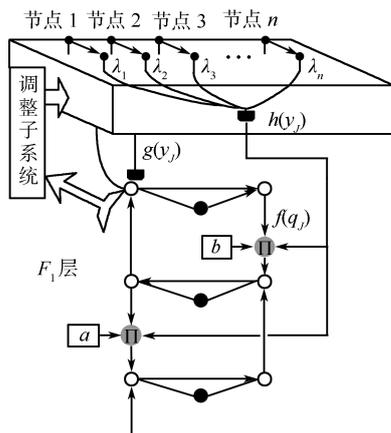


图3 ART2wNF 结构  
Fig. 3 Structure of ART2wNF

类似  $F_2 \rightarrow F_1$  反馈函数  $g(y_J)$ , 定义函数  $h(y_J)$ , 用于反馈当前被激活节点的活跃度.

$$h(y_J) = \begin{cases} \lambda_J, & \text{若当前胜出节点 } J \text{ 没有被复位} \\ h_{old}, & \text{否则} \end{cases} \quad (9)$$

$h(y_J)$  相当于一个选通器, 将当前被激活节点  $J$  的活跃度反馈回  $F_1$  层. 而在还没有节点被激活 (正在进行第一次

$F_1$  层计算) 的情况下, 保持原有的输出  $h_{old}$ . 该选通器的初始输出值设置为一个大于 0 的正数即可, 下一节的定理 1 将证明该值的设置对  $F_1$  层的第一次稳定运算没有影响.

在 ART2wNF 中, 实际参与运算的参数  $a^* = a\lambda_J$ ,  $b^* = b\lambda_J$ , 且  $\lambda_J < 1$ . 由于活跃度随学习过程改变, 等价于参数  $a$  和  $b$  在动态变化, 同时代表不同类别的  $F_2$  层节点具有不同的活跃度, 从而实际运算的  $a^*$ 、 $b^*$  参数值也随着当前被激活的节点不同而不同.

3.2.2 算法可行性证明

然而在 ART2 的离散算法中,  $F_1$  层经历了两次 STM 向量的稳定过程, 分别在  $F_2$  层活跃前后. 在  $F_2$  层激活前, 由于尚未确定被激活的节点  $J$ ,  $\lambda$  的取值也无法确定, 因此,  $F_1$  层的  $a^*$ 、 $b^*$  亦无法确定, 计算将无法进行.

在 ART2-A 中, 由于结构的特殊性, Carpenter 直接给出了在  $F_2$  没有激活之前, 图 1 (b) 中向量  $\mathbf{p} = \mathbf{I}$  的结论, 运算不受参数  $a$ 、 $b$  大小的影响. 我们将在定理 1 给出证明, 对常规 ART2 网络,  $\lambda_J$  在  $F_2$  层激活前的取值也不会影响  $F_1$  层的计算结果.

**定理 1.** 在  $F_2$  层未激活时,  $F_1$  层 STM 向量  $\mathbf{u}$  的计算结果仅与输入向量  $\mathbf{I}$  相关, 而与  $a$  和  $b$  的取值无关 ( $a > 0$ ,  $b > 0$ ).

**证明.** 在  $F_2$  层未激活时, 由于所有  $g(y_i) = 0$ , 故  $\mathbf{p} = \mathbf{u}$ , 进入匹配度计算的关键是向量  $\mathbf{u}$  的值.

1) 如果阈值  $\theta = 0$ , 由文献 [4] 式 (71) 可知:

$$\begin{aligned} \mathbf{u} &= \mathfrak{N}(\mathfrak{N}(\mathbf{I} + a\mathbf{u}) + b\mathfrak{N}(\mathbf{u})) = \\ &= \mathfrak{N}\left(\frac{\mathbf{I} + (a + bA)\mathbf{u}}{A}\right) = \\ &= \frac{1}{B}(\mathbf{I} + a + bA\mathbf{u})A \end{aligned}$$

其中,  $A = \|\mathbf{I} + a\mathbf{u}\|$ ,  $B = \|\mathbf{I} + (a + bA)\mathbf{u}\|$ .

由于  $a$ 、 $b$  均为正数, 输入只有一个  $\mathbf{I}$ , 显然  $\mathbf{u}$  的方向与  $\mathbf{I}$  相同, 同时  $\|\mathbf{u}\| = 1$ , 故  $\mathbf{u}$  与参数  $a$ 、 $b$  大小无关.

2) 如果  $0 < \theta \leq 1/\sqrt{m}$ , 令  $\Omega = \{i, I_i/\|\mathbf{I}\| > \theta\}$ ,  $I_i$  为输入向量的第  $i$  个分量, 定义向量  $\Psi$  为

$$\psi_i = \begin{cases} I_i, & \text{若 } i \in \Omega \\ 0, & \text{若 } i \notin \Omega \end{cases}$$

由图 1 的  $F_1$  层结构和计算过程可知,  $F_1$  层底层 (Bottom layer) 和中间层 (Middle layer) 之间的迭代, 即在  $\mathbf{I} \rightarrow \mathbf{w} \rightarrow \mathbf{x} \rightarrow \mathbf{v} \rightarrow \mathbf{u}$  的过程中, 易知  $\mathbf{u} = \mathfrak{N}(\Psi)$ , 等价于输入向量为  $\Psi$ . 此后,  $\mathbf{w} = \mathbf{I} + a\mathbf{u}$ , 因为  $a > 0$ , 故  $w_i$  ( $i \in \Omega$ ) 的值增加, 并导致  $x_i$  ( $i \in \Omega$ ) 被增强, 而  $x_i$  ( $i \notin \Omega$ ) 的值在  $\mathbf{w} \rightarrow \mathbf{x} \rightarrow \mathbf{v}$  的计算过程中继续被削弱, 迭代计算后, 仍然有  $\mathbf{u} = \mathfrak{N}(\mathbf{v}) = \mathfrak{N}(f(\mathbf{x})) = \mathfrak{N}(\Psi)$ .

由于  $F_2$  层不活跃,  $F_1$  层的中间层和顶层 (Top layer) 之间的迭代, 即  $\mathbf{u} \rightarrow \mathbf{p} \rightarrow \mathbf{q} \rightarrow \mathbf{v}$  的过程中, 有  $\mathbf{q} = \mathbf{p} = \mathbf{u} = \mathfrak{N}(\Psi)$ , 则  $\mathbf{v} = (\mathbf{q}) + f(\mathbf{x}) = (b + 1)\mathfrak{N}(\Psi)$ , 进而有  $\mathbf{u} = \mathfrak{N}(\mathbf{v}) = \mathfrak{N}(\Psi)$ , 也等价于实际输入向量为  $\Psi$ . 由 1) 可知,  $\mathbf{u}$  的稳定值与  $a$  和  $b$  无关.  $\square$

在定理 1 的支撑下, 当  $F_2$  层没有有效激活节点时, 式 (9) 中函数  $h$  的输出保持原有值  $h_{old}$  即可. 这样对使用集成电路实现模拟型 ART2wNF 来讲也非常便利. 除了以上变化, 其他均与常规 ART2 相同, LTM 向量的学习算法也采用快速学习规则即可. 由于每个  $F_2$  层节点都配备了一个活跃

度指示器, 并且同一时刻每个  $F_2$  层节点的值可以不同. 如果是一个学习多次的熟悉类别胜出,  $\lambda_J$  较大, 系统表现出较强的稳定性; 反之, 如果是一个相对陌生的类别胜出,  $\lambda_J$  较小, 系统表现出较强的可塑性.

### 3.2.3 算法总结

首先为  $F_2$  层的每个节点附加了一个活跃度指示器, 初始化为略大于 0 的正数.

采用下述幼态延续算法:

1) 向量输入.  $F_1$  层第一次稳定过程中, 令  $h(y_J) = 1$ , 等同常规 ART2 网络, 计算  $F_1$  层各 STM 向量. 此后,  $h(y_J)$  直接使用上轮保留下来的  $\lambda_J$ ;

2)  $F_2$  层激活. 按常规 ART2 网络选择  $F_2$  层被激活节点  $J$ , 在返回 LTM 向量  $z_J$  的同时, 返回对应的活跃度  $\lambda_J$ ;

3)  $F_1$  层 STM 向量的再次计算.  $F_2$  层返回 LTM 向量后, 与 STM 向量  $p$  相加, 再次进行其他 STM 向量的计算. 此时, 按式 (9) 返回激活节点对应的活跃度  $\lambda_J$  至  $F_1$  层;

4) 谐振产生或重置. 若发生谐振, 更新活跃度指示器, 若发生重置则重复 2) 和 3);

5) 更新活跃度. 按式 (8) 或其他设计模式更新活跃度, 转入 1).

除此之外, ART2wNF 的计算步骤与常规 ART2 网络相同, LTM 向量的学习规则可采用快速学习或者慢速学习.

## 4 ART2wNF 的学习过程示例

### 4.1 学习样本

我们在  $30^\circ$  角附近按标准差  $\sigma = 5$  的正态分布随机产生单位长度为 1 的 50 个向量  $I_i = [\cos(\theta_i), \sin(\theta_i)]$ , 如表 1 所示. 其中, 44 号样本 (\*) 角度最大, 48 号样本 ( $\nabla$ ) 角度最小. 样本集空间分布如图 4 所示.

常规 ART2 网络参数设置为:  $a = b = 5, c = 0.1, d = 0.9, \rho = 0.8$  (有意降低警戒值, 将所有 50 个样本归为一类), ART2wNF 的活跃度变化规律按式 (8) 设置. 图 1 中  $z_{i,J}$  和  $z_{J,i}$  均以  $z_J$  代表, 其初始值为 0, 初始相角也定义为  $0^\circ$ .

### 4.2 稳定性-可塑性分析

#### 4.2.1 可塑性

##### 4.2.1.1 单一样本集合实验

完成以下两个步骤的仿真实验:

**步骤 1.** 将角度最小的 48 号样本与 1 号样本对调位置, 然后, 按编号顺序分别送入快速学习的 ART2、慢速学习的 ART2 和 ART2wNF 网络学习, 记录  $F_2 \rightarrow F_1$  层 LTM 向量  $z_{J,i}$  的相角变化曲线;

**步骤 2.** 将角度最大的 44 号样本与 1 号样本对调位置, 重复上一步实验.

两次学习的 LTM 向量  $z_J$  的相角轨迹分别如图 5 中  $30^\circ$  相角直线的上下两边所示, 由图 5 可知:

1) 慢速学习和快速学习都容易受到样本输入顺序的影响, 仅仅一个样本输入顺序不同,  $z_J$  分别从两侧缓慢逼近样本中心 ( $30^\circ$  角), 慢速学习受影响程度尤其明显.

2) 相对而言, ART2wNF 受样本输入顺序的影响明显减弱. 这正是因为在学习的初期, 该类别的活跃度  $\lambda$  还不高, 等价于式 (6) 中的  $\varepsilon$  相对较小, 网络的可塑性强. 虽然第一个特殊样本对  $z_J$  进行快速定型, 但在此后学习过程中, 剩下的输入样本按随机顺序产生, 在连续输入多个样本后,  $\lambda$  上升, 系统很快克服第一个样本带来的不良影响, 样本中心基本确定. 两次实验中,  $z_J$  逐渐重合, 进入稳定状态.

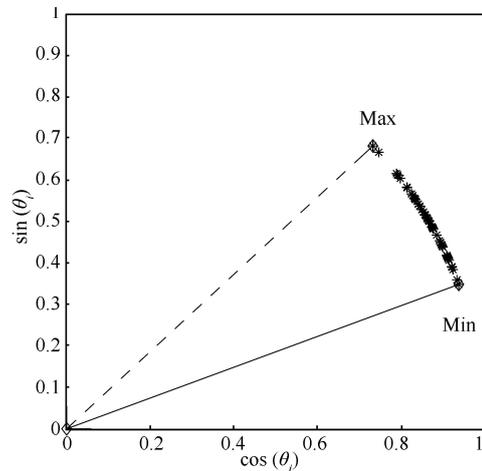


图 4 样本的空间分布

Fig. 4 Distribution of samples

表 1 服从正态分布的 50 个角度样本

Table 1 50 samples belong to normal distribution

No.	$\theta_i$	No.	$\theta_i$	No.	$\theta_i$	No.	$\theta_i$	No.	$\theta_i$
1	25.68	11	24.55	21	26.92	31	37.10	41	24.26
2	30.39	12	30.16	22	33.74	32	31.46	42	30.52
3	23.93	13	32.76	23	29.04	33	30.99	43	33.61
4	24.43	14	35.50	24	34.44	34	37.94	44*	42.93
5	29.97	15	37.72	25	26.18	35	25.98	45	26.67
6	37.66	16	30.43	26	22.99	36	33.48	46	30.94
7	26.15	17	22.54	27	22.89	37	34.18	47	29.59
8	31.86	18	26.29	28	32.44	38	28.78	48 $\nabla$	20.33
9	28.87	19	24.69	29	29.11	39	31.09	49	27.80
10	35.59	20	41.75	30	29.02	40	24.17	50	21.03

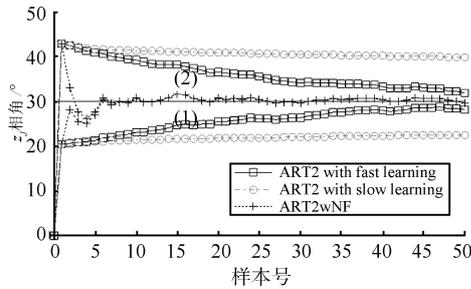


图5 三种网络的 LTM 向量  $z_J$  轨迹  
Fig. 5 LTM vector traces of three networks

要说明的是本文仅讨论自上而下的 LTM 向量  $z_J$ , 自下而上的 LTM 向量  $z_I$  情况有所不同 (例如其初始相角为  $45^\circ$ ), 由于不影响本文结论, 不单独绘制图形说明.

4.2.1.2 统计实验

进一步, 随机产生 500 组数据 (每组 50 个样本, 不进行任何次序交换) 送入三种网络进行学习, 观察在三种网络中 LTM 向量  $z_J$  的轨迹集合, 如图 6 所示.

从 LTM 向量  $z_J$  的轨迹包络线来看, 面对同样的输入样本集合, ART2wNF 受样本差异和输入顺序的影响明显小于常规 ART2 网络, 能够更快地找到类别中心. 这样的结果得益于在初始状态的高可塑性.

4.2.2 稳定性

只要待聚类样本的同一类对象持续刺激  $F_2$  层同一个节点, 其活跃度  $\lambda$  将非常接近 1. 这意味着此时 ART2wNF 的参数  $a^*$  和  $b^*$  已分别接近常规 ART2 网络的  $a$  和  $b$ , 达到与常规 ART2 网络几乎相同的稳定性水平. 而常规 ART2 网络想要达到 ART2wNF 在学习初期的活跃度水平, 参数  $a$  和  $b$  就只能设为一个较小值, 但此时稳定性又得不到保障.

在与 ART2 的横向对比中, 为了获得更好的稳定性, 可以为 ART2wNF 设定一个更大的参数  $a$  和  $b$ . 例如将 ART2wNF 的参数设置为  $a = b = 10$ , ART2 保持在  $a = b = 5$ , 重复图 5 的对比实验后, 再将第一个样本送入系统学习 50 次, 有意破坏网络的知识结构 (即所谓模式漂移), 结果如图 7 所示 (第 51~100 个输入均为 48 号或 44 号).

由图 7 可知, 采用了较大的参数  $a$  和  $b$ , ART2wNF 依然在学习初期保持了类似图 5 非常好的可塑性, 而在学习后期, 稳定性也比常规 ART2 强. 因此, 对比 ART2, ART2wNF 兼顾了可塑性和稳定性, 能够更最大限度地满足实际应用需求.

4.3 动态平衡能力

将角度最大的 44 号样本取出, 作为“干扰样本”插入表

1 第 1 号样本前面. 图 8(a) 中 30 度角上方曲线中的黑点是学习最大相角的 44 号样本后, LTM 向量  $z_J$  的相角值. 在继续输入其他样本后, LTM 的轨迹变化如后面的细线所示. 第二次实验插入到第二个样本前面, 第三次实验插入到第三个样本前面, 如此类推重复 50 次.

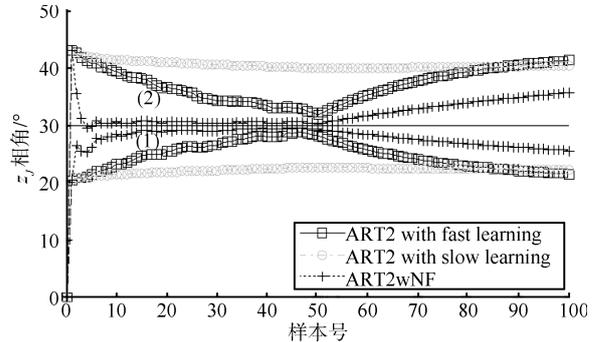


图7 LTM 向量  $z_J$  的稳定性说明  
Fig. 7 Stability of LTM vector  $z_J$

50 次实验中, 在快速学习的 ART2 和 ART2wNF 在学习 44 号样本后, 立刻标识出 LTM 向量  $z_J$  的位置, 如图 8(a) 和 (b) 中的黑点所示.

在文献 [2] 第 XII 小节关于稳定性-可塑性平衡问题的讨论中, 主要分析了几种非正常参数 (例如  $a$  或  $b$  参数为 0, 警戒值  $\rho$  为 0 等) 情况下, ART2 网络的稳定编码能力. 我们认为对于正常网络参数, ART2 也存在可塑性与稳定性平衡问题, 主要体现在:

1) 定型之前 ART2 的  $F_2$  层节点具备强可塑性. ART2 通过快速定型完成类别学习, 如图 8(a) 中横线上方, 如果第一个输入的是表 1 中最大相角的 44 号样本, LTM 向量的相角被定型在  $43^\circ$  左右, 此后的输入通过慢速编码, 将其缓慢地校正到  $30^\circ$  附近.

2) 定型之后具备强稳定性. 如图 8(a) 中横线下方, 第一个输入是表 1 中的 1 号样本, 则快速定型在  $26^\circ$  左右, 此后 44 号样本无论出现在哪个位置, 对 LTM 的学习轨迹来讲, 都没有明显的差异. 说明一旦定型, ART2 已经进入强稳定性状态, 单个奇异样本不足以使 LTM 向量发生显著变化.

对比图 8(a) 中先输入 44 号样本, 再输入 1 号样本和先输入 1 号样本, 再输入 44 号样本两种情况, 在学习完前两个样本后, 两种情况下 LTM 向量的相角位置确实差异很大, 几乎完全取决于第一个进行快速定型的样本的相角. 这正是许多研究都提到的 ART2 受样本输入次序影响较大的缺陷.

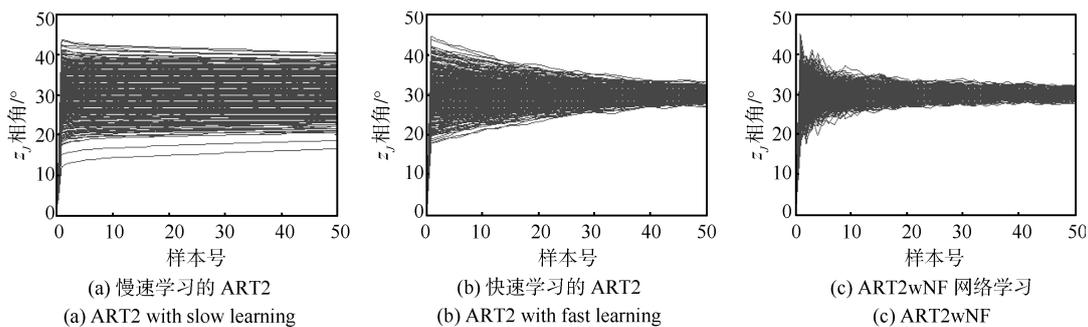


图6 LTM 向量  $z_J$  的轨迹对比  
Fig. 6 LTM comparison of LTM vector  $z_J$  tracks

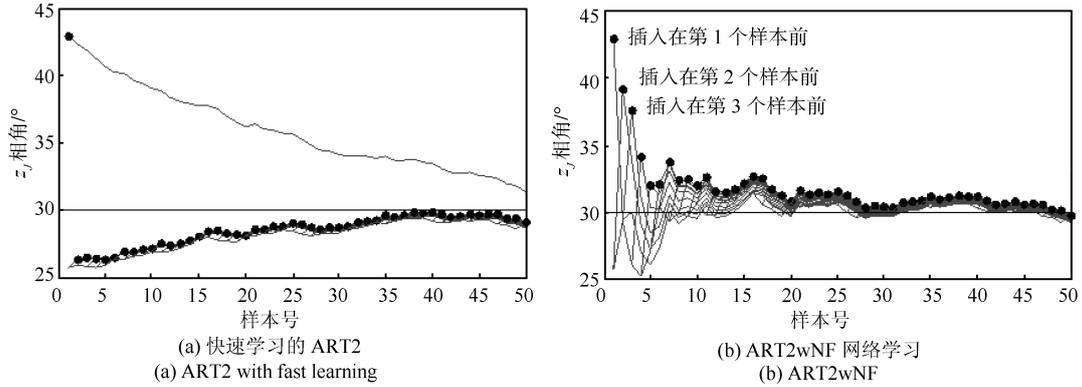


图 8 ART2 与 ART2wNF 的 LTM 向量稳定过程

Fig. 8 Stabilizations of LTM vector of ART2 and ART2wNF

图 8 (b) 中 ART2wNF 的聚类行为则不同:

1) 先输入 44 号样本 (42.93°), 然后, 再输入 1 号样本 (25.68°), LTM 向量  $z_j$  的相角调整到 29° 左右; 反之, 则调整到 39° 左右. 对比图 8 (a) ART2 的强稳定性, 在仅学习两个样本时, ART2wNF 更趋向于相信第二个样本的准确性 (LTM 调整幅度取决于活跃度上升速率);

2) 图 8 (b) 中, 当 44 号样本排在第 3 个输入时, 相对排在第 2 个的情况, 其对 LTM 向量的偏移作用更弱. 随着对特定类别的认识逐渐深入, 干扰样本对 LTM 向量的影响越弱.

由上述分析可知, 常规 ART2 直接快速定型, 此后, 按相同的速率进行慢速编码, 缓慢寻找聚类中心. 而 ART2wNF 的长期记忆系统在刚开始的时候, 具有较高的可塑性, 随着学习样本数量的增多, 稳定性-可塑性平衡点在不断变化, 具有类似人类幼态延续的认知发展特点.

### 5 结论

#### 5.1 创新性

ART2wNF 网络的学习也应属于折中学习规则, 与 ART2-A 的学习方式对比: 1) ART2-A 修改了重置波发生的判定方式 (比较  $I$  与  $p$ ), ART2wNF 的重置波发生条件不变 (仍比较  $u$  与  $p$ ); 2) ART2-A 在激活节点为未定型节点和已定型节点时, 分别使用不同的权值更新方式, ART2wNF 只使用形式最简单的快速学习.

ART2wNF 具有以下显著特点:

#### 1) 稳定性-可塑性的多点动态平衡

根据实际出现的频率, 可以动态调整 ART2 网络中不同类别的平衡点. 在同一时间, 对不同呈现频率的类别具有不同的适应性. 既可保证对新出现的类别具有较强可塑性, 又能使已定型的类别保持较强的稳定性;

#### 2) 适用性

Capenter 用具有折中学习方式的 ART2-A 完成快速定型与慢速编码特性, 只能应用于特定类型的 ART2 网络结构. ART2wNF 无需对 ART2 网络本身的算法修改, 只添加一个活跃度变化机制即可 (如果活跃度始终是 1, 就是常规 ART2 网络), 这种改进方法也使得它可以应用于任何一种 ART2 网络的变形结构.

在本文中, 我们通过一个相对简单的二维数据样本集来说明 ART2wNF 与常规 ART2 的性能差异, 并随机产生 500 组样本数量为 50 的集合从统计的角度观察结果. 通过仿真分析结果不难看出, ART2wNF 模拟了人类认知发展的

特点, 抗干扰和聚类能力得到提升. 但必须承认, 这种改善是针对可能存在特殊输入顺序的. 对于具有正态分布特性的样本, 如果首先输入系统的是出现概率较小的样本, 使用 ART2wNF 处理具有明显优势, 但一般的输入次序则与常规 ART2 网络区别不显著. 因此, ART2wNF 在聚类能力方面的提升, 在统计层面上更容易观察到其性能的改进.

#### 5.2 研究展望

Tenebaum 等在回顾最近 30 年来关于人是如何获取知识方面的研究时<sup>[22]</sup>, 认为认知模型设计者已经开始正视先天主义论和联结主义论两种传统的认知发展理论在认知建模问题不足, 尝试将之前提到的结构化的知识表示和最先进的贝叶斯统计工具结合起来, 运用层次贝叶斯模型来处理数据<sup>[23-24]</sup>.

本文的前期工作主要研究如何依据认识心理学中的图式理论基本原理, 使用 ART2 网络对人类认识过程进行建模<sup>[14]</sup>. 本文提出的 ART2wNF 网络具备了稳定性-可塑性动态平衡能力, 为基于图式理论的认知建模奠定网络结构基础. 下一步的研究中, 计划结合贝叶斯原理和语言动力学理论<sup>[25-27]</sup> 来完善 ART2wNF 认知过程的动态建模.

#### 致谢

感谢台湾交通大学陈思翰博士提供 ART2 网络的 Matlab 源程序初稿和相关研究资料.

#### References

- 1 Zhou Zhi-Hua, Chen Zhao-Qian, Chen Shi-Fu. Review of adaptive resonance theory. *Computer Science*, 1999, **26**(4): 54-56, 79 (周志华, 陈兆乾, 陈世福. 自适应谐振理论综述. *计算机科学*, 1999, **26**(4): 54-56, 79)
- 2 Carpenter G A, Grossberg S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*, 1987, **37**(1): 54-115
- 3 Carpenter G A, Grossberg S. ART 2: self-organization of stable category recognition codes for analog input patterns. *Applied Optics*, 1987, **26**(23): 4919-4930
- 4 Carpenter G A, Grossberg S, Rosen D B. ART2-A: an adaptive resonance algorithm for rapid category learning and recognition. *Neural Networks*, 1991, **4**(4): 493-504
- 5 Carpenter G A, Grossberg S. ART 3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures. *Neural Networks*, 1990, **3**(2): 129-152

- 6 Carpenter G A, Grossberg S, Reynolds J H. ARTMAP: supervised real-time learning and classification of nonstationary data by a self-organizing neural network. *Neural Networks*, 1991, **4**(5): 565–588
- 7 Yao Ming-Hai, Qu Xin-Yu, Li Jia-He, Gu Qin-Long, Tang Li-Ping. Study on Q-learning algorithm based on ART2. *Control and Decision*, 2011, **26**(2): 227–232  
(姚明海, 瞿心昱, 李佳鹤, 顾勤龙, 汤丽平. 基于 ART2 的 Q 学习算法研究. *控制与决策*, 2011, **26**(2): 227–232)
- 8 Chen Zhong, Li Wei. Moving object detection based on ART2 network. *Journal of Changsha University of Science and Technology (Natural Science)*, 2012, **9**(1): 54–59  
(陈众, 李维. 基于 ART2 网络的运动目标检测. *长沙理工大学学报(自然科学版)*, 2012, **9**(1): 54–59)
- 9 He Tao, Zhao Ying-Ying. An improved character recognition algorithm based on ART2 neural network. *Journal of Guilin University of Electronic Technology*, 2012, **32**(3): 237–239  
(何滔, 赵莹莹. 一种改进的基于 ART2 神经网络的文字识别算法. *桂林电子科技大学学报*, 2012, **32**(3): 237–239)
- 10 Noh M S, Hong D S. Implementation of remote monitoring system for prediction of tool wear and failure using ART2. *Journal of Central South University of Technology*, 2011, **18**(1): 177–183
- 11 Yang Xu-Hua. Study on Neural Networks Machine and Its Application in Control [Ph. D. dissertation], Zhejiang University, China, 2004  
(杨旭华. 神经网络及其在控制中的应用研究 [博士学位论文], 浙江大学, 中国, 2004)
- 12 Brüne M. Neoteny, psychiatric disorders and the social brain: hypotheses on heterochrony and the modularity of the mind. *Anthropology & Medicine*, 2000, **7**(3): 301–318
- 13 Chen Zhong, Cai Zi-Xing, Ye Qing. Color pixel categorization based on ART2 network. *Journal of Image and Graphics*, 2008, **13**(4): 634–641  
(陈众, 蔡自兴, 叶青. 基于 ART2 网络的彩色像素分析及其应用. *中国图象图形学报*, 2008, **13**(4): 634–641)
- 14 Chen Zhong. Realization of Cognitive Developmental Process in Schema Theory with ART2 Network and Its Application [Postdoctoral Report], Central South University, China, 2007  
(陈众. 图式理论关于认知发展过程描述的 ART2 网络实现及其应用. *中南大学控制科学与工程博士后流动站出站报告*, 中国, 2007)
- 15 Chen Z, Liu R, He L. Supervised ART2 network with the features of the developmental process of human cognition. In: *Proceedings of the 7th World Congress on Intelligent Control and Automation*. Chongqing, China: IEEE, 2008. 3754–3759
- 16 Zuo Ren-Xia, Li Wei-Qi, Pi-Ya-Jie, Fa Sheng Ren Shi Lun Wen Xuan. Shanghai: East China Normal University Press, 1991  
(左任侠, 李其维. 皮亚杰发生认识论文选. 上海: 华东师范大学出版社, 1991)
- 17 Mergel B. Instructional Design & Learning Theory [Online], available: <http://www.usask.ca/education/coursework/802papers/mergel/brenda.htm>, March 7, 2013
- 18 Chen Z, Wang M, He L. Neoteny learning rule of ART2 network and its function. In: *Proceedings of the 6th International Conference on Natural Computation*. Yantai, China: IEEE, 2010. 407–411
- 19 Xue G, Dong Q, Chen C S, Lu Z L, Mumford J A, Poldrack R A. Greater neural pattern similarity across repetitions is associated with better memory. *Science*, 2010, **330**(6000): 97–101
- 20 CREB. [Online], available: <http://baike.baidu.com/view/1229458.htm>, March 6, 2013
- 21 Hermann Ebbinghaus and His Research on Remembrance. [Online], available: <http://student.zjzk.cn/courseware/zjxlx/experiment/Ebbinghaus.htm>  
(艾宾浩斯及其记忆研究. [Online], available: [http://student.zjzk.cn/course\\_ware/zjxlx/experiment/Ebbinghaus.htm](http://student.zjzk.cn/course_ware/zjxlx/experiment/Ebbinghaus.htm), March 7, 2013)
- 22 Tenenbaum J B, Kemp C, Griffiths T L, Goodman N D. How to grow a mind: statistics, structure, and abstraction. *Science*, 2011, **331**(6022): 1279–1285
- 23 Gopnik A, Glymour C, Sobel DM, Schulz LE, Kushnir T, Danks D. A theory of causal learning in children: causal maps and Bayes nets. *Psychological Review*, 2004, **111**(1): 3–32
- 24 Kemp C, Tenenbaum J B. Structured statistical models of inductive reasoning. *Psychological Review*, 2009, **116**(1): 20–58
- 25 Wang Fei-Yue. Fundamental issues in research of computing with words and linguistic dynamic systems. *Acta Automatica Sinica*, 2005, **31**(6): 844–852  
(王飞跃. 词计算和语言动力学系统的基本问题和研究. *自动化学报*, 2005, **31**(6): 844–852)
- 26 Mo Hong, Wang Fei-Yue, Xiao Zhi-Quan, Chen Qian. Stabilities of linguistic dynamic systems based on interval type-2 fuzzy sets. *Acta Automatica Sinica*, 2011, **37**(8): 1018–1023  
(莫红, 王飞跃, 肖志权, 陈茜. 基于区间二型模糊集合的语言动力系统稳定性. *自动化学报*, 2011, **37**(8): 1018–1023)
- 27 Mo Hong. Linguistic dynamic orbits in the time varying universe of discourse. *Acta Automatica Sinica*, 2012, **38**(10): 1585–1594  
(莫红. 时变论域下的语言动力学轨迹. *自动化学报*, 2012, **38**(10): 1585–1594)



陈众 长沙理工大学电气与信息工程学院副教授. 2003 年获得重庆大学工学博士学位. 主要研究方向为人工智能, 电力系统运行与控制. 本文通信作者.

E-mail: [chenzhong74@126.com](mailto:chenzhong74@126.com)

(CHEN Zhong Associate professor at the School of Electric and Information Engineering, Changsha University of Science and Technology. He received his Ph. D. degree from Chongqing University in 2003. His research interest covers AI and operation and control of power system. Corresponding author of this paper.)



莫红 长沙理工大学电气与信息工程学院副教授. 2004 年获得中国科学院研究生院工学博士学位. 主要研究方向为语言动力系统与智能计算. E-mail: [mohong72@gmail.com](mailto:mohong72@gmail.com)

(MO Hong Associate professor at the School of Electric and Information Engineering, Changsha University of Science and Technology. She received her Ph. D. degree from Graduate University of Chinese Academy of Science in 2004. Her Research interest covers linguistic dynamic systems and intelligent computing.)