

一种新的自适应谐振算法*

陈兆乾 周戎 刘宏 陈世福

(南京大学计算机系 南京 210093)

摘要 本文提出了一个综合多种神经网络理论的学习算法 FTART (field theory-based adaptive resonance theory), 它将 ART (adaptive resonance theory) 算法、Field Theory 和 ARTMAP 等算法的优点有机结合, 并以样本在实例空间出现的概率为启发信息修改分类。FTART 由于采用了不同于其它算法的冲突解决和动态扩大分类区域的方法, 因此取得了较好的效果。本文还对实现 FTART 算法的结果进行了验证。

关键词 神经网络, 自适应谐振理论, 域理论。

神经网络学习算法分为前馈型、联想型和竞争型 3 种, 其中前馈型的 BP 算法在实践中获得了较大的应用, 但其算法要求进行多遍学习, 学习时间较长, 而且当需要重新学习时, BP 算法必须将所有的样本全部再学一遍, 在实际应用中的效率较低。联想型算法的容量问题一直难以解决, 无论是理论上还是实际应用上都需要较大的突破。竞争型的算法有许多种, 较典型的 ARTMAP^[1] 算法是在 ART (adaptive resonance theory)^[2] 算法的基础上改进而来的, 它能通过任意顺序输入的样本矢量进行增量式的有导师学习, 即只需一遍学习即可, 这就使其比 BP 算法更加实用, 学习效率有显著提高。在此基础上又发展了 Fuzzy ARTMAP^[3] 算法, 扩展了对模糊属性的学习能力。但是, ARTMAP 仍然存在一些缺点, 主要是它对样本空间的划分采用长方形, 这在实际应用中造成了神经元数目增长太快, 对空间划分的效率不高; 算法未充分利用样本中的联系, 不同的样本类间容易造成冲突, 致使网络分类退化以及网络训练的最终结果不对应各个分类的中心等问题。

经过一段时间的研究, 我们在 ARTMAP 及其他算法的启发下, 提出了一个新的学习算法, 该算法结合以上算法的特点, 实现了新的机制, 使性能获得较大改善, 我们将该算法称为 FTART (field theory-based ART), 它综合了 Field Theory^[4] 和 ART 以及 ARTMAP 算法的优点, 采用了类似于 Field Theory 的响应函数, ART 的基本算法和 ARTMAP 的组织结构, 实现了高效性和增量学习能力, 经过与 ARTMAP 及 BP 算法的比较, 确认该算法在样本数远少于 ARTMAP 时即可达到其精确度, 实现了对样本空间的有效划分, 并且该算法

* 本文研究得到国家自然科学基金资助。作者陈兆乾, 女, 1940 年生, 教授, 主要研究领域为机器学习, 专家系统。周戎, 1972 年生, 硕士, 主要研究领域为机器学习。刘宏, 女, 1971 年生, 硕士, 主要研究领域为机器学习。陈世福, 1938 年生, 教授, 博士生导师, 主要研究领域为知识工程, 机器学习, 图象处理。

本文通讯联系人: 陈兆乾, 南京 210093, 南京大学计算机系

本文 1996-05-24 收到修改稿

只需一遍学习,因此具有增量式学习能力,克服了 BP 算法在这方面的固有缺陷. FTART 已在 Windows 环境下用 Borland C++ 实现,并完成了“基准测试”验证.

1 算法概述

1.1 基本响应函数

BP 算法中第 2 层神经元的响应函数一般为 Sigmoid 函数(S-函数),其数学形式如下:对于每一个神经元 b_i 和输入矢量 \vec{v}_i ,其激活值为:

$$b_i = f\left(\sum_{h=1}^n v_{hi} a_h + \theta_i\right) \quad (1)$$

其中, f 为 S-函数:

$$f = \frac{1}{1 + e^{-x}} \quad (2)$$

该函数的形状类似 S 形,当 $\sum_{h=1}^n v_{hi} a_h + \theta_i \gg 0$ 时,函数趋向 +1,当 $\sum_{h=1}^n v_{hi} a_h + \theta_i \ll 0$ 时,函数趋向 0.

FuzzyART 算法中,对于每一个输入矢量 \vec{I} 和第 2 层节点 j ,响应函数定义为:

$$T_j(\vec{I}) = \frac{|\vec{I} \wedge \vec{w}_j|}{\alpha + |\vec{w}_j|} \quad (3)$$

其中, \wedge 是模糊“与”操作符,定义为:

$$\vec{p} \wedge \vec{q} \equiv \min(p_i, q_i) \quad (4)$$

而 $|\dots|$ 定义为:对 M 维空间的任意矢量 \vec{p} ,有

$$|\vec{p}| \equiv \sum_{i=1}^M |p_i| \quad (5)$$

当 $T_j(\vec{I})$ 大于阈值时,输入矢量属于权值矢量所表示的子类.

在 Field Theory 中,响应函数是类似库仑定律的公式:

$$\vec{E}_u = - \sum_{i=1}^m \frac{\vec{u} - \vec{x}_i}{\|\vec{u} - \vec{x}_i\|^L} \quad (6)$$

其中 \vec{E}_u 是在 \vec{u} 点的“场矢量”, \vec{u} 代表“测试电荷”的空间位置矢量, \vec{x}_i 是第 i 个样本矢量, $\|\dots\|$ 是 2 个矢量间的欧几里德距离, L 是一个常数($L=2$ 即代表普通的静电场). 这个响应函数的形状是类钟型曲线,但在 $\vec{u} = \vec{x}_i$ 时, \vec{E}_u 趋向 $+\infty$.

FTART 中采用的响应函数实际上有 2 种,对于第 3 层神经元来说,响应函数为 S-函数,即如公式(1)、(2)所示,对第 2 层神经元的输出矢量起归一化的作用,而第 1、2 层神经元的连接权以及第 2 层神经元的响应函数则采用钟型的 Gaussian 函数,其数学表示如下:对于输入样本矢量 \vec{v} 在第 i 个输入神经元上的分量 v_i ,第 1、2 层连接权 b_{ij} 的激活值为:

$$b_{ij} = e^{-\frac{(v_i - \theta_{ij})^2}{\alpha_{ij}}} \quad (7)$$

其中 α_{ij} 是神经元的响应特征宽度, θ_{ij} 是神经元的响应中心值(阈值),当输入 $v_{ij} = \theta_{ij}$ 时,激活值 = 1,当输入偏离 θ_{ij} 时,激活值趋向于 0. 第 2 层神经元的激活值则为其连接权的激活值的简单加和.

采用以上 2 种形式的响应函数基于以下几点考虑:

(1)BP 网络所用的响应函数对每一个输入节点只有递增或递减的响应值,因此,两层的感知器(Perceptron)^[5]无法完成对任意形状的分类边界的学习. BP 网络的第 3 层的作用是对第 2 层的输出再进行一次分类,以完成对复杂分类边界的学习,当某一个学习空间未被样本完全覆盖时,算法的结果是对空洞进行简单的合并,即将空洞和最邻近的分类区域分为一类,从而导致了前馈型算法的 2 个缺点——反复学习和两层感知器在样本空间不能线性分割时出现震荡. 克服该缺陷的方法是:使用相对较简单的分类区域对样本空间进行第 1 次划分. 在 FTART 中采用超椭圆形对样本空间进行划分,每一个第 1 层节点采用钟形函数对输入矢量的分量进行响应,函数的响应中心值对应经学习后该分量的特征值,这样,经过第 1 层便可对样本空间进行比较复杂的划分,第 2 层节点的功能可以得到化简,采用这样的结构可达到一遍学习的要求,类似于 Field Theory 中的解决方法.

(2)Field Theory 类算法所用的响应函数为类库仑定律的形式,与钟形的 Gaussian 函数类似,但由于库仑公式在 \vec{u} 趋向 \vec{x}_i 时趋向无穷大,容易导致溢出,因此在计算机中的实现精度难以保证,如果压缩公式的输出范围则使精度降低. 而 FTART 采用了 Gaussian 函数和不同的算法,克服了溢出和精度问题且不降低算法的效率.




图1 ARTMAP算法的响应域

(3)Fuzzy ART 及 Fuzzy ARTMAP 算法中所用的响应函数基于模糊理论的“逻辑与”算符,该算符对 2 个矢量进行逻辑与时,相当于在超空间中取 2 个矢量所夹的最小矩形,如图 1 所示. 而后,将所得矢量与权值矢量的各个分量的绝对值的和进行比较,确定输入矢量与权值矢量的相似度. 由此可知,对于每一个权值矢量,其吸引域为方形,如图 1 中双点划线所围的方框所示,这种响应函数的优点是计算简单,

但在分类边界较复杂时,需要大量的方形吸引域覆盖类边界. 因此,这种响应函数并不是最佳的,当边界比较复杂时,椭圆形吸引域比较容易填满类空间,而不致留下空隙. 而且 ARTMAP 及 Fuzzy ART 的吸引域的边界是确定性的,即要么属于某个吸引域,要么不属于,而 FTART 采用的响应函数则对学习空间的大部分区域都有定义,可以只用少量的权值矢量覆盖整个样本空间,而不降低网络的分类能力.

(4)Gaussian 函数的形式如公式 7 所示,它是第 1、2 层神经元间的连接权以及第 2 层神经元的响应函数,而第 3 层神经元的响应函数为 Sigmoid 函数,该函数的作用是将第 2 层神经元的输出归一化,并以此函数的输出为准进行第 2 层神经元间的竞争,确定最大相似的权值向量.

1.2 互联结构

FTART 网络由 4 层神经元组成,第 1 层神经元为输入神经元,该层神经元与第 2 层神经元全互联,将每一个输入矢量的分量传给连接第 1、2 层神经元的“突触”(连接权),由连接权经 Gaussian 函数变换后传给第 2 层神经元,第 2 层神经元则成组地与第 3 层神经元连接,与同一个第 3 层神经元相连的一组神经元属于同一类. 当激活值传到第 2 层后,该层神经元经过竞争,将最大的激活值作为该组神经元的输出传给第 3 层神经元,所有的第 3 层神经元之间再经过竞争,得出最后取胜的神经元,而后,取胜的神经元将激活对应的第 4 层神经元,

获得相应的特征输出.系统的结构如图 2 所示.

这个结构实际上是一个竞争型的 3 层网络分类器,可以形成对样本集的任意形状划分.第 1、2 层神经元的连接权对输入矢量进行变换,确定对应的第 2 层神经元所代表的亚类的隶属度,在第 2 层神经元之间进行竞争,获胜的神经元激发对应的第 3 层神经元,第 3 层神经元之间的竞争则确定了输入矢量所属的分类,第 3、4 层神经元之间的连接权代表了分类的特征分量.使用以上结构,既具有神经网络分类器的优点,又可应用于广泛的问题领域中,有较强的适应性.




图 2 FTART 网络的结构

1.3 训练方法

当训练开始时,首先将问题所需的输入、输出节点数及决定分类精度的参数提供给系统,据此构成一个初步的网络开始训练.当训练时,所有的样本顺序输入(每个样本只输入一次,次序任意),首先输入第 1 层神经元,该层神经元直接将输入矢量的各个分量传入与其相连的所有连接权,连接权的响应函数为 Gaussian 形式,输入经变换后传入所有的第 2 层神经元,产生该层神经元的输出,所有同类神经元的输出进行竞争,获胜的神经元的输出送给相连的第 3 层神经元,再在第 3 层神经元之间进行竞争,竞争获胜的第 3 层神经元激活其与第 4 层神经元的连接权,产生相应的特征输出,将该输出矢量与样本输出矢量进行比较,若在允许误差范围内则产生鼓励信号,将其逐级反馈至正确分类中激活值最大的第 2 层神经元,再将鼓励信号传给所有与其相连的 1、2 层连接权,连接权根据以下公式对其 Gaussian 激活函数中的响应中心值 θ_{ij} 和响应特征宽度 α_{ij} 进行修改:

$$\theta'_{ij} = \begin{cases} \theta_{ij} & v_{ij} \in [\theta_{ij} - 0.3\alpha_{ij}, \theta_{ij} + 0.3\alpha_{ij}] \\ \frac{\theta_{ij} + 0.3\alpha_{ij} + v_{ij}}{2} & v_{ij} \in (-\infty, \theta_{ij} - 0.3\alpha_{ij}) \\ \frac{\theta_{ij} - 0.3\alpha_{ij} + v_{ij}}{2} & v_{ij} \in (\theta_{ij} + 0.3\alpha_{ij}, +\infty) \end{cases} \quad (8)$$

$$\alpha'_{ij} = \begin{cases} \alpha_{ij} & v_{ij} \in [\theta_{ij} - 0.3\alpha_{ij}, \theta_{ij} + 0.3\alpha_{ij}] \\ \frac{\theta_{ij} + 0.3\alpha_{ij} + v_{ij}}{2} & v_{ij} \in (-\infty, \theta_{ij} - 0.3\alpha_{ij}) \\ \frac{v_{ij} - (\theta_{ij} - 0.3\alpha_{ij})}{2} & v_{ij} \in (\theta_{ij} + 0.3\alpha_{ij}, +\infty) \end{cases} \quad (9)$$

在学习过程中,仅对 1、2 层神经元间的连接权进行学习修改,将响应中心值和响应特征宽度向当前输入矢量调整,使最相似的那个第 2 层神经元的输出增大.

若第 4 层的输出矢量与训练样本矢量误差过大,则禁止所有的第 3 层神经元的输出,用训练样本矢量激活第 4 层神经元,寻找与该矢量误差最小的第 3 层神经元的特征输出,如该输出矢量与训练样本矢量的误差在允许范围内,则认为这个第 3 层神经元为正确的输出,让其拥有鼓励信号,进行回传,送入激活值最大的第 2 层神经元,按公式(8)、(9)进行权值修改,直至相应的第 3 层神经元能够在竞争中获胜.

当找不到具有合适的特征输出的第 3 层神经元时,系统激发一个添加新神经元的子系统,它根据样本所引起的周围神经元的响应度(激活值)在现有网络的第 2 层和第 3 层各添

加一个新的神经元:新的第 2 层神经元根据当前第 1 层(输入层)神经元的输出,形成与各个输入神经元的连接权,连接权的响应中心值为输入神经元的输出,响应特征宽度为系统默认值;新的第 3 层神经元与新的第 2 层神经元相连,与第 4 层神经元的连接权的输出设为该类的特征输出,并使该神经元在前面的第 2 层神经元兴奋时具有比周围神经元稍高的输出,以便在竞争中获胜。

若找到了具有合适特征输出的第 3 层神经元,但其连接的所有第 2 层神经元的输出都低于系统所设的最低阈值时,添加新神经元的子系统亦被激发,根据输入矢量的各个分量设置一个新的第 2 层神经元,将它添加到网络中。

1.4 判别方法

当网络训练完毕后,即可开始对输入的矢量进行判别,判别方法很简单,与训练方法一致,只是去掉了网络判别后的学习修改过程.为完整起见,以下进行比较详细的解释:网络的第 1 层神经元得到输入矢量后,将其传给第 1、2 层神经元间的连接权,连接权经 Gaussian 函数变换后,传给第 2 层神经元,第 2 层神经元经简单加和后,即得出输入矢量对该“亚类”的隶属度,传入第 3 层神经元,在每一个第 3 层神经元中进行第 2 层神经元的输出的竞争,确定输入矢量属于那一个“亚类”,获胜的第 2 层神经元的输出即为该第 3 层神经元的输出,而后,在第 3 层神经元间竞争,确定输出最大的第 3 层神经元,则该神经元所属的类为输入矢量所属的类,根据其第 4 层神经元的连接权的输出确定第 4 层神经元的激活值,由此即得到网络的输出。

2 与其他算法的比较

2.1 ART & ARTMAP 算法

FTART 和 ART 以及 ARTMAP 都属于竞争型算法,但 ART 和 ARTMAP 基于自组织模型,在学习时,形成具有固定大小的决策域,当样本不属于任何决策域时,形成新的包含该样本的决策域. ART 算法的分类精度需要人工确定,一旦所确定的精度过低,则需重新学习,难以进行增量式学习,而且,由于决策域不能扩大,造成隐层结点数过多. ARTMAP 也具有上述缺点,不过,ARTMAP 能实现有导师学习,在此基础上对错误分类进行动态调整,能够在一定程度上解决增量式学习中的问题.而 FTART 更进一步实现了决策域的动态扩大,因此从根本上解决了上述问题。

2.2 Field Theory

Field Theory(域理论)在自组织神经网络中存在广泛的应用,其中最简单的是模拟静电场的模型,它为神经网络分类器提供了一种简洁的思路,但其实现存在以下问题:

系统可能会有过冲(Overshoot)或不稳定.这是由于模拟测试电荷在静电场中的运动是用离散的步骤进行的,而 Field Theory 的场矢量公式当距离接近于 0 时趋向无穷大,在用计算机模拟时导致一个很大的过冲且有可能不稳定。

当测试电荷离训练电荷很远时场矢量太小,致使收敛很慢。

由于数字式计算机的离散性,可能使测试电荷在训练电荷之间静止。

由 Field Theory 发展而来的 RCE(restricted coulomb energy system)及 NLS^[6]算法通过引入简化的公式及投票策略(Voting Methods)而改善了上述缺点,但依然存在类似于

ARTMAP 的缺点,这主要是由于 Field Theory 类算法所采用的冲突解决算法和决策域扩大算法比较简单,不能有效地提高分类效率.而 FTART 算法采用了公式(6)、(7)解决了上述问题,获得了更高的效率.

3 模拟结果及比较

为了验证 FTART 算法的有效性,在 Windows 3.1 环境下用 Borland C++ 4.0 及 OWL 2.0 类库实现了该算法,并对 2 个神经网络中的基准测试问题采用 FTART 算法学习,并将学习结果与其它算法的结果(尤其是 ARTMAP 算法)进行了比较.其中,CIRCLE-IN-THE-SQUARE 问题是 DARPA 的 ANNT (artificial neural network technology) 计划所采用的神经网络系统的性能评价基准问题;分辨 2 个螺旋形则是 Lang 和 Witbrock^[7] 提出的问题.

3.1 CIRCLE-IN-THE-SQUARE

CIRCLE-IN-THE-SQUARE 问题要求系统分辨在 1 个正方形中的点是否落在 1 个圆形区域内,该圆形区域的面积等于正方形的一半.

Wilensky^[8] 检验了 $2-n-2$ 层 BP 算法求解该问题的结果,他研究的系统隐层单元数 n 介于 5~100,对应的连接数介于 21~401,样本数介于 150~14 000. 为避免过冲,当系统训练精度达到 90% 时停止训练. 含 20~40 个隐层结点的系统训练最快,经 5 000 次学习循环后达到了对样本集 90% 的精度,对测试例的分类精度也接近 90%.

Carpenter 等^[2] 也提出了 Fuzzy ARTMAP 的结果,如表 1 所示(同时列出了 FTART 的比较数据),需要指出的是 Fuzzy ARTMAP 的分类区域是长方形的,最后对圆形区域的分类由不同的长方形所组成.

表 1 训练结果比较

	样本数	样本集训练精度	测试集精度	分类数
	100	99.00%	88.60%	12
Fuzzy	1 000	95.50%	92.50%	21
ART-MAP	10 000	97.70%	96.70%	50
	100 000	98.80%	98.00%	121
	100	100%	49.80%	40
FT-ART	500	100%	98.90%	75
	1 000	100%	99.10%	110

FTART 算法采用的样本数从 100~1 000,对于所有的训练样本,都达到了 100% 的分类精度,在 1 000 个样本时对整个样本空间的分类结果如图 3 所示,图中所出现的灰色斑点是由于训练样本分布不均匀,造成了一些区域训练后无法分辨,因而标为未定义.


可以从表中看出,在样本数较小时,Fuzzy ARTMAP 的测试集精度比 FTART 高,但在样本集数量增大时,FTART 的精度迅速提高,其增长速度比 Fuzzy ARTMAP 快得多,在样本数仅为 500 时,就超过了 Fuzzy ARTMAP 在样本数为 100 000 时的测试集精度,为 98.9%,且分类数也仅有 Fuzzy ARTMAP 的 62%. 在样本数为 1 000 时,用 110 个分类达到了 99.1% 的精确度. 而 BP 网络的隐层单元为 20~40 时,经过 5 000 次循环达到 90% 的

分类精度. 由此可见, FTART 比 Fuzzy ARTMAP 及 BP 网络学习系统的学习归纳能力更强.



1 000 个样本, 99.10% 测试精度, 110 个分类

图 3 灰色斑点为未定义



测试精度 100%, 114 个分类, 散布图中的点为样本点

图 4 灰色部分为未定义

3.2 分辨 2 个螺旋形

分辨 2 个螺旋形的问题由 A. P. Wieland^[7] 提出, 用作神经网络系统的基准测试. 问题中的 2 个螺旋形在平面上绕了 3 圈, 每 1 圈给出 32 个样本点, 加 1 个结束点, 共 97 个样本点. 在训练过程中, 最外层的样本点首先输入, 2 个螺旋形的样本点交替输入, 也即输入样本集如 $(a^{(1)}, b^{(1)}), (a^{(2)}, b^{(2)}), \dots, a^{(t)} = (a_1^{(t)}, a_2^{(t)}) \in \mathcal{R}^2, b^{(t)} = (b^{(t)}) \in \mathcal{R}^1$. 对于 $n=1, 2, \dots, 97$,

$$a_1^{(2n-1)} = 1 - a_1^{(2n)} = r_n \sin \alpha_n + 0.5 \tag{10}$$

$$a_2^{(2n-1)} = 1 - a_2^{(2n)} = r_n \cos \alpha_n + 0.5 \tag{11}$$

其中 $r_n = 0.4 \left[\frac{105-n}{104} \right], \alpha_n = \frac{\pi(n-1)}{16}, b^{(2n-1)} = 1[\text{白}], b^{(2n)} = 0[\text{黑}]$.

Lang 和 Witbrock 构造了一个 BP 系统用于学习分辨在这 2 个螺旋形上的点, 结果标准 BP 系统不能稳定地学习, 为此他们构造了一个特殊的 2-5-5-5-1 系统, 在该系统中, 每个神经元与后续层中的所有神经元互联. 加上每个神经元的偏置权, 系统共有 138 个训练权. 使用 vanilla back-propagation^[9] 训练权值平均需 20 000 循环, 而用 quickprop 算法需 8 000 循环.

表 2 训练结果比较

	分类数	测试集精确度	参数值
Fuzzy	47	96.40%	0.90
ART-MAP	78	99.00%	0.95
	194	100.00%	1.00
FT-ART	92	97.10%	0.30
	114	100.00%	0.20

对于 Fuzzy ARTMAP 算法, 需要调整组成子网的 Fuzzy ART 网络的警戒参数 \bar{P}_a ^[2], \bar{P}_a 不同, 结果的精度和分类数也不同. FTART 的结果也和参数 α_{ij} 有关, α_{ij} 不同, 结果精度和分类数也不一样. 两者的比较结果如表 2 所示. 从中可以得出结论: 在参数变化时, Fuzzy ARTMAP 的分类数变化较大, 参数值变化了 10%, 而分类数增加了 312%, 精确度只变化了 4%. 当然, 由于 2 个算法的参数意义不同, 如此简单的比较不能得出很有意义的结论. 另外一点是, 当 Fuzzy ARTMAP 算法达到 100% 精确度时产生了 194 个分类, 具有 582 个权

值,而 FTART 算法用了 114 个分类达到了 100% 的精确度,具有 342 个权值,因此 FTART 的结果归纳性更强。

4 结束语

FTART 算法是基于 ART 理论,Field Theory,ARTMAP 算法等的基础上产生的一种有导师学习算法,其最大的特点是具有增量式学习能力,与其它算法的不同之处主要是 FTART 解决分类冲突的方法公式(8)、(9)以及动态扩充分类的方法,由于这 2 点,FTART 算法的效率比其它算法有了提高。

参考文献

- 1 Moore B. ART 1 and pattern clustering. In: Proc. 1988 Connectionist Models Summer School, 1989. 174~185.
- 2 Carpenter G A, Grossberg S, Reynolds J H. ARTMAP: supervised real-time learning and classification of non-stationary data by a self-organizing neural network. *Neural Networks*, 1993, 4: 565~588.
- 3 Carpenter G A, Grossberg S, Markuzon N *et al.* Fuzzy ARTMAP: a neural network architecture for incremental supervised learning of analog multidimensional maps. *IEEE Trans. on Neural Networks*, 1992, 3(5): 698~713.
- 4 Wasserman P D. *Advanced methods in neural computing*. Chapter 2. 1993. 14~34.
- 5 Rosenblatt F. *The perceptron: a perceiving and recognizing automation*. Cornell Aeronautical Laboratory Report, 85-460-1, 1957.
- 6 Wasserman P D. *Advanced methods in neural computing*. Chapter 2. 1993. 26~33.
- 7 Lang K J, Witbrock M J. Learning to tell two spirals apart. In: Proc. 1988 Connectionist Models Summer School, 1989. 52~59.
- 8 Wilensky G. Analysis of neural network issues: scaling, enhanced modal processing, comparison with standard classification. DARPA Neural Network Program Review, Oct. 1990.
- 9 Rumelhart D E, Hinton G, Williams R. Learning internal representations by error propagation. In: Rumelhart D E and McClelland J L eds., *Parallel Distributed Processing*, Cambridge, MA: MIT Press, 1986.

A NEW ADAPTIVE RESONANCE THEORY ALGORITHM

Chen Zhaoqian Zhou Rong Liu Hong Chen Shifu

(Department of Computer Science Nanjing University Nanjing 210093)

Abstract This paper proposes a neural network learning algorithm FTART (field theory-based adaptive resonance theory) that combines many neural network theories. It is based on the main idea of ART (adaptive resonance theory) and makes use of many merits of Field Theory and ARTMAP, etc., and corrects the classification regarding the supposed possibility of examples in the instance space. FTART gains some goodness by employing a special conflict resolution process and dynamically expanding the classification area. Some benchmark test results are also given.

Key words Neural network, adaptive resonance theory, field theory.