

文章编号:1001-9081(2006)03-0659-04

一种改进的 ART2 网络学习算法

徐艺萍^{1,2}, 邓辉文^{1,2}, 李阳旭³

(1. 西南大学 逻辑与智能研究中心, 重庆 400715; 2. 西南大学 计算机与信息科学学院, 重庆 400715;
3. 成都信息工程学院 电子商务系, 四川 成都 610225)
(world.1230@163.com)

摘要:分析了现有 ART2 网络存在的问题,提出了一种改进的 ART2 算法。该算法首先利用样本数据自身来初始化权值,然后按照同一类中的数据点到其聚类中心的距离之和越小(即类内偏差越小),聚类效果越好的原则来设计特征表示场和类别表示场之间的权值修正公式,最后通过比较输入样本和聚类中心的模来有效地利用模式的幅度信息。分析证明了该算法不仅能有效解决模式漂移问题、充分利用幅度信息,而且能提高聚类速度。

关键词:ART2 网络;幅度信息;模式漂移;聚类

中图分类号:TP181 **文献标识码:**A

An improved ART2 neural network clustering algorithm

XU Yi-ping^{1,2}, DENG Hui-wen^{1,2}, LI Yang-xu³

(1. *Research Center of Logic and Intelligence, Southwest University, Chongqing 400715, China;*
2. *School of Computer and Information Science, Southwest University, Chongqing 400715, China;*
3. *Department of Electronic Commerce, Chengdu University of Information Technology, Chengdu Sichuan 610225, China*)

Abstract: By analyzing ART2 neural network clustering algorithm, an improved ART2 neural network clustering algorithm was proposed. This algorithm applied the sample data to initialize its weights, then designed the formula of modifying weights between feature representation layer and class representation layer based on the principle that the distance between each data in the same class and their clustering center was nearer, clustering result was better. The amplitude information was used by comparing module of input data and clustering center. The analysis illustrates that this algorithm can solve pattern drifting, use amplitude information well, and arise clustering speed.

Key words: ART2 neural network; amplitude information; pattern drifting; clustering

0 引言

目前,聚类分析的方法主要有两种——统计聚类法和神经网络法。统计聚类法包括系统聚类法、动态聚类法、模糊聚类法、最优分割法等。神经网络法是近年研究较多,发展较快的一种新的聚类方法。可以用于聚类分析的神经网络包括 BP 网络、模糊神经网络、自组织映射网络、自适应谐振网络等,本文主要讨论自适应谐振网络。自适应谐振网络模型是由美国 Boston 大学数学系自适应系统中心的 Grossberg 和 Carpenter 于 1987 年 3 月提出的。目前,该模型有 3 种不同结构:ART1^[1],ART2^[2]和 ART3^[3],它们在功能和实现方面形成了一个不断完善的系列。ART1 是最基本的,它只能处理离散数据特征;ART2 既可以处理离散数据特征,也可以处理模拟数据特征;ART3 结构最复杂,目前不太实用,它将人脑模型中的神经元突触生物化学运行机理应用于神经网络。它们都具备无监督学习和实时处理的优点,其中 ART2 型神经网络使用最为广泛,因此,本文主要讨论 ART2 型神经网络,并将它用于聚类分析中,但是该网络存在以下三个缺点:

- 1) 权值的初始化方法和参数 d 的选择不尽合理;
- 2) 存在模式漂移现象;

3) 由于该网络结构中固有的归一化环节,使得在处理数据过程中丢失了幅度信息。

对于最后两点,尽管有很多文章提出了解决方法^[4,5],但是并未能充分利用幅度信息和解决模式漂移问题。基于此本文提出了一种改进算法,该算法不仅能解决模式漂移问题、充分利用幅度信息,而且能够提高聚类速度。

1 传统 ART2 网络

1.1 ART2 网络基本结构和原理

ART2 网络用于聚类分析具有在学习新的模式时不破坏已存储的模式优点,既可以快速识别已存储的模式,又能迅速适应未学习过的新对象,实现快速聚类。同时它还可以通过调整警戒参数 ρ 来协调网络的稳定性和可塑性,在实际应用中可以适应不同程度的分类要求。因此,ART2 网络是一种非常适合于聚类分析的神经网络,具有良好的发展前景。

ART2 网设计的基本思想是采用竞争学习和自稳学习机制,其输入可以是任意模拟向量,结构如图 1 所示。图中只画出了第 j 个处理单元的结构,系统可以分为注意子系统和调整子系统两部分。其中,注意子系统完成由底向上矢量的竞争选择及矢量间相似程度的比较;调整子系统检查相似度能否

收稿日期:2005-09-26 修订日期:2005-12-28 基金项目:国家社会科学基金资助项目(NSSF04BZX046)

作者简介:徐艺萍(1980-),女,重庆人,硕士研究生,主要研究方向:模糊聚类、模糊控制、神经网络; 邓辉文(1964-),男,重庆人,教授,博士生导师,主要研究方向:人工智能; 李阳旭(1975-),女,四川成都人,硕士,主要研究方向:神经网络、模糊控制。

达到满意的标准,并做出相应的动作,成功或者重置。系统结构分为 F_1 场和 F_2 场, F_1 场称为特征表示场,主要完成对输入的去噪处理、归一化处理,以及将处理结果与某一类模式中心进行线性组合的工作。图中 $f(\cdot)$ 是种非线性运算,为了抑制噪声而突出有用信号。 $a, b, c, d, \theta, \rho, e$ 是神经网络的参数,参数 a 和 b 反映 F_1 内部的反馈大小,影响中层模式 U 向输入模式 X 靠近的快慢,取值不能太大也不能太小,否则会导致分类结果的不稳定。 c, d 应满足 $\frac{cd}{1-d} < 1$, 且 $\frac{cd}{1-d}$ 越接近 1, 网络对误配越敏感。参数 θ 是 F_1 层非线性变换的阈值,它的大小决定对基底噪声的抑制程度,通常接近于 0。 ρ 是系统的警戒参数,控制 F_1 层对输入向量的编码和 F_2 层返回的类代表向量进行比较达到匹配的程度, ρ 取值越大,分类越细,取值越小,分类越粗略。通过警戒参数的取值,可以协调网络的可塑性和稳定性,使两者达到平衡。 e 的作用是当没有输入信号的时候使活化能保持有限,通常 $e = 1$ 。




图1 ART2网络的基本结构

F_1 场的运算过程具体描述如下:

$s_j = x_j + au_j$, 其中 $j = 0, 1, \dots, M-1, M$ 为输入向量的

维数。 $z_j = \frac{s_j}{e + \|s\|}$, 其中 $\|\cdot\|$ 表示求模运算。

$v_j = f(z_j) + bf(q_j)$, 其中 $f(x) = \begin{cases} x, & x \geq \theta \\ 0, & \text{其他} \end{cases}$

$u_j = \frac{v_j}{e + \|v\|}$

$p_j = u_j + \sum_{i=0}^{N-1} g(y_i)w'_{ij}$

其中 $g(y_j)$ 为 F_2 层第 i 个神经元的输出函数, $g(y_i) = \begin{cases} d, & i = I \\ 0, & \text{其他} \end{cases}$, I 为选定的类别号(即获胜神经元), N 为当前的类别数。

$q_j = \frac{p_j}{e + \|p\|}$

F_2 场称为类别表示场,它根据 F_1 场的输出和 F_1 与 F_2 场间的权重系数找出最为相似的模式, F_2 场的输入矢量 T_i 为:

$T_i = \sum_{j=0}^{M-1} p_j w_{ji}, i = 0, 1, 2, \dots, N-1$

按照竞争学习的机制,如果 F_2 场中的第 I 个节点被激活(即第 I 个节点获胜),即 $T_I = \max\{T_i\}, i = 0, 1, 2, \dots, N-1$, 则有输出:

$y_i = \begin{cases} 1, & i = I \\ 0, & \text{其他} \end{cases}$

将获胜节点送到调整子系统,检测输入模式与记忆模式

的相似度,计算公式为:

$$\|r\| = \left[\sum (r_j)^2 \right]^{1/2}, r_j = \frac{u_j + cp_j}{e + \|cp\| + \|u\|}$$

若 $\|r\| + e < \rho$ (其中 ρ 为给定阈值, $0 < \rho < 1$), 则 F_2 层竞争获胜的神经元所对应的权重系数 w'_{ij} 不能与输入模式匹配,当前激活节点被重置并被屏蔽,并在剩余的节点中继续搜寻最匹配的。如果所有节点均不能通过警戒测试,则在 F_2 层开辟一个新节点,即创建一个新类。否则,按照以下公式调整 F_1 场和 F_2 场间的权重系数 w_{ji} 和 w'_{ij} :

由底向上 ($F_1 \rightarrow F_2$):

$$\frac{dw_{ji}}{dt} = g(y_i)(p_j - w_{ji}) = d(1-d) \left[\frac{u_j}{1-d} - w_{ji} \right] \quad (1)$$

由顶向下 ($F_2 \rightarrow F_1$):

$$\frac{dw'_{ij}}{dt} = g(y_i)(p_j - w'_{ij}) = d(1-d) \left[\frac{u_j}{1-d} - w'_{ij} \right] \quad (2)$$

经过以上过程,ART2 网络便完成了对输入模式 X 的识别。

1.2 传统 ART2 算法的不足

传统的 ART2 网络虽然具有快速学习功能,但是存在权值的初始化方法和参数 d 的选择不尽合理,存在模式漂移现象和在处理数据过程中丢失了幅度信息等缺点,这样很可能会导致分类错误。




图2 (3)式的向量表示法

传统的 ART2 算法以及其算法的改进是将自上而下 w'_{ij} 的权值初始化为 0,将自下而上的权值 w_{ji} 初始化为小于等于 $\frac{1}{(1-d)\sqrt{M}}$ 的固定值。文献[1]中, w_{ji} 采用这种初始化方法是为了保证在竞争过程中不会首先选择一个新的节点作为获胜神经元,而是先考虑已经存在的节点是否适合输入模式。但这是不必要的,因为只有当已经存在的所有节点都不适合当前输入模式才会建立新的节点。所以,如果已经建立了一个新节点,就可以直接初始化新节点为当前的输入模式。使用这种初始化方法,初始权值不仅不能随着样本数据的改变而改变,而且有可能与样本数据相距很远。再者这种初始化方法是根据权值的修正公式导出来的,由于传统的 ART2 算法中的权值修正公式存在模式漂移和容易遗忘已经学习过的输入模式等问题,所以由它导出权值 w_{ji} 的初始化方法不够合理。文献[6]也分析了参数 d 的选取方法, $d \gg 1$, 且 $cd \approx 1$ 时, $\|r\|$ 更为准确地反映了两模式的相似程度。所以当参数 d 取值越大, $\frac{1}{(1-d)\sqrt{M}}$ 越接近 0, 即 w_{ji} 越接近 0。这样,对于远离 0 向量的输入模式 X_k , 距离初始权值 w_{ji} 和 w'_{ij} 就会比较远,要经多次修正 w_{ji} 和 w'_{ij} 才能接近 X_k , 故这种初始化权值的方法收敛速度也比较慢。

传统的 ART2 算法中的参数 d 设置为 $0 \leq d \leq 1$, 这也是根据权值的修正公式得到的。由(1)式和(2)式可知,在每个输入模式学习结束时,权值 w_{ji} 和 w'_{ij} 都近似等于 $\frac{U}{1-d}$ 。如果

$d > 1$, 那么对于每一个输入模式, 权值 w'_{ij} 和输入模式的相位信息相反, 这样计算出来的相似度 $\|r\|$ 阈值就等于 1 (即所有的模式都归为一类), 很难对输入模式进行分类。同时, 文献[1] 也分析了 d 的取值不能太小, 所以导致在大多数文章中都取 $d = 0.9$, 但是, 由于权值修正公式的不合理, 从而导致参数 d 的设置也不尽合理。

模式漂移现象主要是由权值的修正方法不合理引起的, 因为传统 ART2 算法的权值修正公式在学习新的输入模式的同时很容易遗忘已经学过的输入模式, 并且由(1)式和(2)式可知, 在每个输入模式学习结束时, 权值都近似等于 $\frac{U}{1-d}$ (仿照(4)式的证明方法也可证明)。这样, 权值总是向当前的输入数据漂移 (即模式漂移现象)。已有很多文章对模式漂移现象进行了讨论^[6,7,9], 其中文献[9]使用的权值修正法是目前使用最广的方法, 权值修正公式如下:

$$w_{ji}(k) = \frac{1}{k} \left[(k-1)w_{ji}(k-1) + \frac{U_j}{1-d} \right] \quad (3)$$

$$w'_{ij}(k) = \frac{1}{k} \left[(k-1)w'_{ij}(k-1) + \frac{U_j}{1-d} \right] \quad (4)$$

但是由图2可知, 按照(3)式和(4)式对权值修正并不能避免模式漂移, 因为对于每一个输入模式, 修正后的权值 $w'(k)$ 与修正前的权值 $w'(k-1)$ 相比, $w'(k)$ 始终是偏向于当前输入的中层模式 U 的。用数学的方法也可以证明按照(3)式和(4)式对权值进行修正不能避免模式漂移。

定理 若按照公式(3)和(4)修正 ART2 网络的权值, 则不能避免模式漂移现象。

证明: 这里只证明用公式(4)修正权重的情况, 用公式(3)也类似。由(4)式得:

$$kw'_{ij}(k) = (k-1)w'_{ij}(k-1) + \frac{U_j}{1-d}$$

$$\text{即 } kw'_{ij}(k) - (k-1)w'_{ij}(k-1) = \frac{U_j}{1-d} \text{。 又因为每次学}$$

习结束时, $w'_{ij}(k) \approx w'_{ij}(k-1)$, 故可得 $w'_{ij}(k) = \frac{U_j}{1-d}$ 。可见, 按照(3)式或(4)式对权值进行修正, 在每次学习结束时, 权值 w' 总是向当前输入的中层模式 U 漂移。这样就导致了随着某类模式的不断进入, 该类的模板会不断地向新加入模式的方向偏移, 最后可能严重偏离模式类中心, 模板就失去了对该类的代表性, 当然也就无法准确辨识新的输入模式。特别是当输入模式呈逐渐变化趋势的时候, 这种现象更为明显, 所以按照(3)式或(4)式对权值进行修正, 仍然不能避免模式漂移现象。

幅度信息的丢失主要是由于数据在网络中的归一化引起的。传统的 ART2 网络是按相位信息分类的, 只要具有相同的相位信息, 则无论幅度相差多大, 都把数据归为一类, 例如: 数据点(1,1)和(1000,1000)。当用传统的 ART2 网络进行聚类时, 由于它们的相位信息相同, 网络会把它们分为一类, 但事实上这两个数据点距离很远, 很有可能不属于同一类。目前, 已有很多文章提出通过比较权值和输入样本的模来恢复幅度信息^[5,7], 但是它们所用的权值并不能反映模式原型的幅度信息。由上面的证明也可以知道: 对于任何的输入模式, 学习结束时得到权值 w' , 且有 $\|w'\| = \frac{1}{1-d}$ 。可见, 每个

权矢量都有相同幅度信息, 这与输入数据的多样性是矛盾的, 所以权值只能反映模式的相位信息, 不能反映模式的幅度信息 (即丢失了模式的幅度信息)。

2 改进的 ART2 网络算法

2.1 权值的初始化方法

本文提出了一种直接用输入样本数据对权值进行初始化的方法, 即让某一模式原型的初始聚类中心直接等于第一次进入该原型的输入样本数据, 再将初始聚类中心归一化即可得到初始权值。由于该方法将初始权值直接与输入模式联系起来, 而无需修正, 所以可以提高网络的收敛速度, 并且该初始权值能随着样本数据的改变而改变, 故这种初始化方法更合理。同时, 按照文献[6]的分析, 当 d 满足 $d \gg 1$ 和 $cd \approx 1$ 这两个条件时, 参数 d 的选择是合理的。

计算初始权值的具体步骤如下:

步骤1 计算初始聚类中心 C_{ij} :

$$C_{ij} = \begin{cases} C_{ij}, & \text{如果第 } i \text{ 类中已经有数据} \\ X_{kj}, & \text{如果第 } i \text{ 类中还没有数据} \end{cases} \quad (5)$$

其中 C_{ij} 表示第 i 个聚类中心的第 j 维, X_k 为第一个进入第 i 类的样本数据, X_{kj} 为第 k 个输入样本的第 j 维。

步骤2 计算初始权值:

$$w'_{ij} = \begin{cases} C_{ij} / \|C\|, & \text{如果第 } i \text{ 类中已经有数据} \\ X_{kj} / \|X\|, & \text{如果第 } i \text{ 类中还没有数据} \end{cases} \quad (6)$$

$$w_{ji} = w'_{ij} \quad (7)$$

2.2 权值的修正方法

本文提出了一种新的权值修正方法, 该方法主要是按照同一类中的数据点到其聚类中心的距离之和越小, 聚类效果越好的原则来设计权值的修正公式。由于该方法在计算聚类中心和权值时, 充分利用了已经学过的输入模式, 因此能有效避免在学习新的输入模式时遗忘已学过的输入模式。而且由于这样得到的聚类中心趋近于该类所有输入模式的中心 (权值也趋近于该类所有输入模式的中心), 而不是像(1)~(4)式那样只向最近一次的输入模式漂移, 故采用这种权值修正方法也能有效避免模式漂移现象。

由于 ART2 中权值修正方法的收敛性, 保证了输入模式如果在第一次提交给网络没有发生重置, 那么在以后权值的修正过程都不会发生重置, 故可以直接对权值进行修正, 而无需每修正一次权值就计算一次 F_1 层中神经元的值和相似度 $\|r\|$ 。由于本文对聚类中心的修正采用了梯度下降法, 故对中心和权值的修正公式是收敛的, 所以本文直接反复修正聚类中心, 直到达到阈值 ζ 为止, 然后再将聚类中心归一化得到权值 w'_{ij} 和 w_{ji} 。

假设当前输入模式 X_j 与第 I 个节点匹配成功, 则具体步骤如下:

步骤1 计算类内偏差 J :

$$J = \sum_{j=1}^{m_I} \|X_j - C_I\|^2 \quad (8)$$

其中, C_I 表示第 I 个聚类中心, m_I 表示第 I 类中数据点的个数。

步骤2 计算 J 对 C_I 的偏导:

$$\frac{dJ}{dC_I} = -2 \sum_{j=1}^{m_I} \|X_j - C_I\| \quad (9)$$

步骤3 按照(10)式修正聚类中心 C_l :

$$C_l(t) = C_l(t-1) + \lambda \frac{dJ}{dC_l} \quad (10)$$

步骤4 重复步骤1~3,直到 C_l 的变化范围满足阈值 ζ 。

步骤5 计算权值:

$$w'_{ij} = C_{ij} / \|C_l\| \quad (11)$$

$$w_{ij} = w'_{ij} \quad (12)$$

2.3 比较输入样本与聚类中心的幅度值

本文增加了一个矩阵 C ,用于存储实际聚类中心, $\|C\|$ 反映了模式原型的幅度信息,这样就便于计算聚类中心和输入样本的模,避免了丢失幅度信息。聚类中心和输入样本的模比较公式如下:

$$\beta = \text{abs}(\|X\| - \|C\|) \quad (13)$$

3 具体算法

改进后的 ART2 网络的具体算法如下(步骤中参数的含义与前面一致):

1) 设置参数 $a, b, c, d, e, \rho, \theta, \beta, m, \zeta, \gamma$ 的值,其中 γ 表示模的阈值,并将所有神经元的输出设为 0 向量。

2) 向网络输入样本 X ,并计算 $\|X\|$ 和 F_1 层各神经元的值,直到 F_1 层达到稳定。

3) 进入 F_2 层进行竞争选择计算,选出最为匹配的一类。

4) 计算相似度 $\|r\|$ 和 β ,判断 $\|r\|$ 是否达到给定的值 ρ , β 是否小于等于 γ ,如果 $\|r\|$ 达到给定的值 ρ ,且 β 小于等于 γ ,则匹配成功,按照(8)~(10)式调整聚类中心,直到聚类中心的变化达到阈值 ζ ,然后按照(11)和(12)式计算场间权值。否则发出重置波,抑制此类,跳到3)寻找另外的类别,如果所有的类别都不适合该样本点,则生成一个新类,此时,初始权值按照(5)~(7)式计算。

5) 输入下一个样本数据,返回2),直到所有的样本都已分类。

4 实例分析

实验一 对文献[11]中的幅角进行分类。该组模式共有 89 个,其幅角分别为 $1^\circ, 2^\circ, \dots, 89^\circ$ 。将本文的方法与传统的 ART2 算法和文献中 BM-ART2 方法比较,如果数据是顺序或逆序输入,结果如表 1 所示。

表 1 顺序输入和逆序输入方式下三种网络的聚类结果

类别	输入方式	ART2		BM-ART2		本文算法	
		范围	规模	范围	规模	范围	规模
1	顺序输入	1~89	89	1~31	31	1~30	30
	逆序输入	89~1	89	89~59	31	89~60	30
2	顺序输入			31~62	31	31~60	30
	逆序输入			58~28	31	59~30	30
3	顺序输入			63~89	27	61~89	29
	逆序输入			27~1	27	29~1	29

如果将数据随机输入,ART2 将模式分为 2 类: $\{1 \sim 41, 45 \sim 50, 52, 54, 59\}$ 与 $\{42 \sim 44, 51, 53, 55 \sim 58, 60 \sim 89\}$ 。第一类中,序号大于 31 的模式共有 19 个,它们与 1 号模式的夹角均大于 30° ;在第二类中,序号小于 58 的模式共有 8 个,它们与 89 号模式的夹角均大于 30° ,超出了警戒参数的限定,故两类均为超大类,超出量分别为 19 与 8。另外,从 42 号至 59 号两

类模式相互重叠交错,交混类组为 1-2,交混量为 9:9;BM-ART2 将模式分为 4 类: $\{0 \sim 21\}$, $\{22 \sim 40\}$, $\{47 \sim 60, 62 \sim 63\}$ 与 $\{61, 64 \sim 89\}$,各类中均没有超出警戒参数的限定,故无超大类。而从 61 号至 63 号,第三、四两类模式相互重叠交错,交混类组为 3~4,交混量为 2:1;本文的方法可将模式分为 3 类: $\{1 \sim 28\}$, $\{29 \sim 60\}$, $\{61 \sim 89\}$,类与类之间无交混。可见,采用本文的方法可使样本的输入顺序对分类结果影响较小,从而分类结果也更合理。

实验二 使用计算机随机生成 2000 个二维数据,采用本文的方法可以将数据分成 9 类,运行时间为 15.17s,而采用传统的 ART2 算法运行时间为 22.06s。可见,本文采用的权值初始化方法能够有效地提高网络的计算速度。

5 结语

ART2 神经网络广泛应用于模式识别中的聚类问题,具有速度快、实时性好和鲁棒性强等优点,尽管如此,仍然存在权值的初始化方法和参数 d 的选择不合理,存在模式漂移现象和在处理数据时存在着丢失模式幅度信息等缺点。为此,本文提出了一种改进的 ART2 算法,该算法首先利用样本数据自身来初始化权值,使权值的初始化更合理,并能提高网络的收敛速度;其次按照同一类中的数据点到其聚类中心的距离之和越小,聚类效果越好的原则来设计 F_1 层和 F_2 层之间的权值修正公式,使聚类中心趋近于该类所有输入模式的中心,故有效避免了模式漂移现象。同时,由于在计算聚类中心和权值时,充分利用了已经学过的输入模式,因此避免了在学习新的输入模式时遗忘已学过的输入模式;通过比较输入样本 X 和聚类中心 C 的模有效地利用了模式的幅度信息,避免了因丢失幅度信息而引起的错误分类。通过实例分析证明了采用本文的方法得到的分类结果更合理、有效和可行。

参考文献:

- [1] CARPENTER GA, GROSSBERG S. A massively parallel architecture for a self-organizing neural pattern recognition machine[J]. Computer Vision, Graphics, and Image Processing, 1987, 37(1): 54-115.
- [2] CARPENTER GA, GROSSBERG S. ART-2: self-organization of stable category recognition codes for analog input pattern[J]. Applied Optics, 1987, 26(23): 4919-4930.
- [3] CARPENTER GA, GROSSBERG S. ART-3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures[J]. Neural Networks, 1990, 3(2): 129-152.
- [4] 韩小云,刘瑞岩. ART-2 网络学习算法的改进[J]. 数据采集与处理, 1996, 11(4): 241-245.
- [5] 申岸伟,俞斌,关海鹰. ART-2 神经网络分类器的研究[J]. 北方交通大学学报, 1996, 20(2): 146-151.
- [6] 艾燕妮,朱学锋. 基于改进算法的 ART2 网络用于微晶玻璃颜色分类[J]. 华南理工大学学报, 2003, 31(1): 74-78.
- [7] 唐红卫,桑农,曹治国,等. ART-2 神经网络的研究与改进[J]. 红外与激光工程, 2004, 33(1): 101-106.
- [8] 闻新,周露,王丹力,等. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000.
- [9] 从爽,郑毅松,王怡雯. ART-2 神经网络的改进及其建模实现[J]. 计算机工程与应用, 2002, 38(14): 25-28.
- [10] 于剑. 论模糊 C 均值算法的模糊指标[J]. 计算机学报, 2003, 8(8): 968-973.
- [11] 钟旭. ART2 神经网络与化学模式聚类分析的研究[D]. 浙江大学, 2004.