

ART-2 神经网络的研究与改进*

唐红卫, 桑 农, 曹治国, 张天序

(华中科技大学 图像识别与人工智能研究所
图像信息处理与智能控制教育部重点实验室, 湖北 武汉 430074)

摘要: ART-2 神经网络可以很好地应用于模式识别中的聚类问题, 但是由于其算法结构中固有的归一化环节, 在处理数据过程中丢失了非常重要的幅度信息。在分析这一不足的基础上, 提出两种改进算法, 同时给出了相应的实验结果。

关键词: 自适应谐振理论; 神经网络; 幅度信息; 相位信息; 相似度

中图分类号: TP391.44 **文献标识码:** A **文章编号:** 1007-2276(2004)01-0101-06

Research and improvements of ART-2 neural networks*

TANG Hong-wei, SANG Nong, CAO Zhi-guo, ZHANG Tian-xu

(Institute for Pattern Recognition and Artificial Intelligence,
Key Laboratory of Ministry of Education for Image Processing and Intelligent Control,
Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: ART-2 Neural Networks are well applied in clustering, but it discard the important information of amplitude of patterns during the procession of input data. Two improved algorithms are presented after analyzing the defect of ART-2 and experimental result is reported.

Keywords: ART-2; Neural networks; Amplitude information; Phase information; Similarity

0 引言

自适应谐振理论(Adaptive Resonance Theory, ART)网络模型是由美国学者 Grossberg 和 Carpenter 提出的, 该模型有 3 种不同结构: ART-1^[1],

ART-2^[2] 和 ART-3^[3], 它们在功能和实现方面形成了一个不断发展的系列。ART-1 用于处理离散数据特征, ART-2 既可以处理离散数据特征, 也可以处理模拟数据特征, ART-3 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, ART-2 还有 ART-2A^[4] 等改进型。它们都具备无监督学习

收稿日期: 2003-04-01; 修订日期: 2003-06-15

* 基金项目: 国家自然科学基金重点项目(60135020)

作者简介: 唐红卫(1977-), 男, 江苏苏州人, 硕士, 主要研究方向为图像处理、模式识别和神经网络。

和实时处理的优点。

文中主要介绍 ART-2 网络模型,参考文献[5]指出该网络存在模式漂移问题,参考文献[6]针对该网络在数据处理过程中存在的幅度丢失现象提出了一种改进算法,但是这种改进算法的性能依赖于样本的学习顺序,因此并没有从根本上解决有效利用样本幅度信息的问题。

1 ART-2 神经网络基本原理

ART-2 神经网络由注意子系统和调整子系统组成,其中注意子系统包括 F_1 场、 F_2 场两个短期记忆层(STM)和处于 F_1 场、 F_2 场之间的长期记忆层(LTM),如图 1 虚线左侧部分所示。图中只画出了维数为 M 的样本 I 的第 i 分量 I_i 的处理结构图。

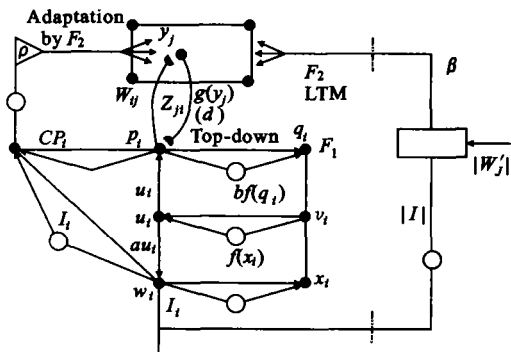


图 1 ART-2 神经网络结构图
Fig. 1 ART-2 network architecture

1.1 F_1 场运算过程

F_1 场为特征表达场,由上、中、下三层组成,包括求和、正规化和非线性处理 3 种运算。图 1 中空圆圈表示正规化运算,实心圆表示求和运算。下层和中层构成一个闭合的正反馈回路,完成的运算为 $w_i = I_i + au_i$, $x_i = w_i / \|w_i\|$ 和 $v_i = f(x_i) + bf(q_i)$, $u_i = v_i / \|v_i\|$, 其中 $f(x)$ 是一个能对小幅度信号进行抑制的非线性处理,其表达式为:

$$f(x) = \begin{cases} 2mx^2 / (x^2 + m^2) & 0 \leq x \leq m \\ x & 0 \geq x \end{cases}$$

中层和上层构成另一个闭合正反馈回路,即 $p_i = u_i + \sum_{j=1}^N g(y_j) Z_j$, $q_j = p_j / \|p_j\|$, 这里 N 为当前聚类别数。

别数。

1.2 F_2 场运算过程

F_2 场为类别表达场,它对由 F_1 场送上的模式 p 进行竞争选择,可以分为上行滤波和下行反馈过程。由模式 p 以及 $F_1 \sim F_2$ 之间的 LTM 权重系数 W 可以得到并行搜索编码模式 T ,第 j 个节点对应的搜索编码模式值为 $T_j = \sum_{i=1}^M p_i W_{ij}$ ($j=1, \dots, N$),式中 W_{ij} 是上行滤波通道的第 j 个输出节点所对应的权值向量,即长期记忆向量的第 i 个分量。在 F_2 场中进行竞争选择出最大相似测度值 T_j ,即 $T_j = \max(T_j | j=1, \dots, N)$,然后产生竞争选择模式 y ,其第 j 个分量的值为 $y_j = \begin{cases} 1 & j=J \\ 0 & j \neq J \end{cases}$ 。

1.3 调整子系统运算过程

图 1 最左侧为调整子系统。 F_2 场选择了 T 向量数值最大的分量所对应的神经元后,必须送到调整子系统中检验。检验向量 $\rho = \frac{I + cp}{\|I\| + \|cp\|}$, 其模为:

$$\|\rho\| = \frac{\|I\|^2 + 2c\|I\|\|p\|\cos(I,p) + c^2\|p\|^2}{\|I\| + c\|p\|} \quad (1)$$

式中 $\|p\|$ 为向量 I 和向量 p 之间的相似性度量。经进一步推算^[7], $\|\rho\|$ 实际上是向量 I 和在 F_2 场中竞争获胜的那个神经元所对应的向量 Z_j 之间的相似性度量。设 ρ_c 为预设的警戒参数,若 $\|\rho\| \geq \rho_c$,说明相似度足够大,系统产生谐振,分类问题得到解决;否则,原选择失效,需从 F_2 场其余神经元中再重新选择。如果所有的神经元都不能满足 $\|\rho\| \geq \rho_c$,就开辟新的神经元节点,建立新类。

1.4 长期记忆权值的调整方式

网络每次对输入的样本进行分类后,应根据本次输入和分类结果对长期记忆权值进行初始化或作相应的调整。如果在本次分类中网络开辟了一个新的节点,则需要对其所对应的长期记忆权值进行初始化,其表达式为:

$$\begin{aligned} W_{i(N+1)}(k+1) &= u_i(k) & i &= 1, \dots, M \\ Z_{(N+1)}(k+1) &= u_i(k) & i &= 1, \dots, M \end{aligned} \quad (2)$$

否则,如果本次分类中样本被识别为某个已存在的输

出端神经元节点 J 所代表的类别,其相应的调整过程为:

$$\begin{aligned} W_{ij}(k+1) &= W_{ij}(k) + d(1-d) \times (u_i(k)/(1-d) - W_{ij}(k)) \quad i = 1, \dots, M \\ Z_{ji}(k+1) &= Z_{ji}(k) + d(1-d) \times (u_i(k)/(1-d) - Z_{ji}(k)) \quad i = 1, \dots, M \end{aligned} \quad (3)$$

式中 J 是竞争获胜或新开辟的神经元节点编号; d 为调整步幅。长期记忆权值矩阵 W 和 Z 记忆储存了模式类别信息,但由于 ART 网络结构中正规化运算的作用,实际上它们只记录了模式类别的相位信息,关于这一点下文将详细介绍。

2 ART-2 神经网络分析

从 ART-2 神经网络的算法结构不难看出,该网络存在严重的不足:网络只利用了模式的相位信息,而丢失了幅度信息。

考察 F_1 场中的 x_i, u_i 和 q_i 的神经元,其运算方程为:

$$x_i = w_i / \|w_i\|, u_i = v_i / \|v_i\|, q_i = p_i / \|p_i\|$$

可以看出,它们完成的正是对输入矢量的正规化。因此,当其应用于存在幅度差异的模式聚类问题时,将导致错误的分类结果。

考虑图 2 所示的分类情况, $A(2,2)$ 、 $B(2,1)$ 和 $C(8,8)$




图 2 原始 ART-2 错误分类例

Fig. 2 An example of misclassification by the original ART-2 network

(8,8) 分别表示二维模式空间中的 3 个样本。经过这种分类器后,由于 A、C 有着完全相同的相位信息,能达到 100% 的相似而被分为一类,而与 A 更接近的 B 则被分为另一类。这种错误的结果就是由 ART-2 网络运作时模式幅度信息的丢失造成的。




图 3 参考文献[6]方法的错误分类例

Fig. 3 An example of misclassification by the method proposed by [6]




图 4 仅采用公式(14)条件的错误分类例

Fig. 4 An example of misclassification by only the condition of equation (14)

针对上述问题,参考文献[6]提出了一种改进的网络结构。它在原 ART-2 网络结构中增加了一个幅度限定子系统,见图 1 中虚线框右边部分。其幅度限定条件为:

$$\beta = (\|X\| - \|W'_j\|) / (\|X\| + \|W'_j\|) \leq \sigma_c \quad j = 1, \dots, N \quad (4)$$

当样本 I 被送入 ART-2 网络后,首先进入幅度限定子系统与所有类别的聚类中心向量 W'_j ($j = 1, \dots, N$) 进行幅度相似度比较,选出满足公式(4)的可能类别,然后再往下处理,即样本 I 进入 F_1 、 F_2 场与上述选出的可能类别进行相位矢量的匹配;如果 I 与所有聚类中心的幅度相似度都不满足公式(4),则直接开辟新类。值得注意的是,由于长期记忆权值 W_j 只存储了样本聚类中心的相位信息,因此它在幅度上区别于聚类中心向量 W'_j 。

这种改进算法由于加进了幅度限定子系统而使分类效果得到改善,但是深入研究可以发现,幅度限定子系统的性能依赖于样本学习顺序,在特定的样本学习顺序下,相离较远的样本依然会聚成一类。

图 3 中 p 为类别 j 的聚类中心,相应的向量为 $W'_j(k-1)$, A 为待聚类样本,且 $\|X_A\| - \|W'_j(k-1)\| = l$,不妨设此时下式成立:

$$\beta_A = (\|X_A\| - \|W'_j(k-1)\|) / (\|X_A\| + \|W'_j(k-1)\|) = l / (2\|W'_j(k-1)\| + l) < \sigma_c$$

于是 A 将进入 F_1 和 F_2 场并与聚类中心满足公式(4)的所有神经元进行竞争选择和取向比较。由于 A 与第 j 类样本的相位信息完全相同,所以将被识别为

类别 j 。经过权值的修改,类别 j 的聚类中心移至 q , 相应的向量修改为 $W'_j(k)$:

$$W'_j(k) = [(k-1)W'_j(k-1) + X_A]/k = \left[(k-1)W'_j(k-1) + W'_j(k-1) + l \frac{W'_j(k-1)}{\|W'_j(k-1)\|} \right] / k$$

假设前 $k-1$ 个输入训练样本均属于第 j 类,取模得到:

$$\|W'_j(k)\| = \|W'_j(k-1)\| + l/k \quad (5)$$

设样本 B 与 q 相距 l ,也即 $\|X_B\| - \|W'_j(k)\| = l$, 它们的幅度相似度为:

$$\beta_B = (\|X_B\| - \|W'_j(k)\|) / (\|X_B\| + \|W'_j(k)\|)$$

显然有:

$$\beta_B < \beta_A < \delta \quad (6)$$

所以同 A 一样, B 在进入 F_1 和 F_2 场后由于与第 j 类样本的相位信息完全相同而被聚识为类别 j , 相应的聚类中心向量修改为 $W'_j(k+1)$,同理有:

$$\|W'_j(k+1)\| = \|W'_j(k)\| + l/(k+1) \quad (7)$$

于是,用归纳假设方法得到:

$$\|W'_j(k)\| = \|W'_j(1)\| + l\left(\frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{k}\right)$$

以上分析了待分类样本比聚类中心向量模值大的情况,如果比聚类中心向量模值小,沿图 3 样本 C 方向变化,经过同样的推导可以得到:

$$\|W'_j(k)\| = \|W'_j(1)\| - l\left(\frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{k}\right) \quad (8)$$

总结这两种情况有:

$$|\|W'_j(k)\| - \|W'_j(1)\|| = l\left(\frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{k}\right) \quad (9)$$

由于 $\sum_{k=2}^{\infty} \frac{1}{k}$ 不收敛,因此当 $k \rightarrow \infty$ 时, $\|W'_j(k)\| \rightarrow \infty$ 。

例如,对于灰度图像的模式聚类问题,如果属于某一

类的图像有 20 幅,则 $l\left(\frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{20}\right) = 2.6l$,再加上样本与聚类中心允许的距离 l ,样本间的幅度差距将达到 $3.6l$,当 $l=10$,这个数值就是 36。更进一步,由于上面的分析中,运用了公式(6)的递归比较,所以得到的聚类中心幅度差的结论还不是最坏的情况。在最坏的情况下有:

$$|\|W'_j(k)\| - \|W'_j(1)\|| > l\left(\frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{k}\right) \quad (10)$$

由此可见,这一幅度限定子系统的判决函数存在着严重的不足,从而使其不能很好地解决 ART 网络幅度丢失的问题。

3 幅度调整子系统的改进

针对幅度限定子系统判决函数的不足,提出了两种改进策略。

(1) 仍采用图 1 所示的网络结构,但幅度限定子系统的判别函数改进为:

$$\|X_k\| - W'_j \leq \beta_c \quad (11)$$

$$\sigma_T = \sqrt{\frac{1}{n_j+1} \left(\sum_{i=1}^{n_j} \|X_j(i) - W_T\|^2 + \|X_k - W_T\|^2 \right)} \leq \sigma_c \quad (12)$$

式中 n_j 为在已训练样本中属于类别 j 的样本个数; $X_j(i)$ ($i=1,2,\dots,n_j$) 为已训练样本中属于类别 j 的各样本,而 $W_T = \left(\sum_{i=1}^{n_j} X_j(i) + X_k \right) / (n_j+1)$ 。

公式(11)去除了原判别函数公式(4)的分母部分,从而减小了聚类中心幅度漂移的能力,使聚类中心最大幅度差的表达式由公式(10)变为公式(9)。而公式(12)的加入将某类模式的标准差限制在一定的数值内,使样本能聚合成紧密的类,从根本上消除了聚类中心漂移的不足。以上两个限定条件缺一不可,上文分析了只有限定条件公式(11)的错误分类情况。如果只有限定条件公式(12),将造成如图 4 所示的分类错误。图中以 p 为聚类中心的某一类样本,由于先前分布得较为集中,标准差较小,当来了一个新样本 A 后,仍然能够满足限定条件公式(12),于是经过

ART 网络下一阶段的运算后,样本 A 被聚为这一类,从而导致错误的分类结果。公式(11)限定条件的加入可以很好地防止这种错误的发生。

(2) 将幅度限定子系统的幅度检验条件和原算法中调整子系统的相位检验条件结合在一起构成新的调整子系统,其结构如图 5 所示。

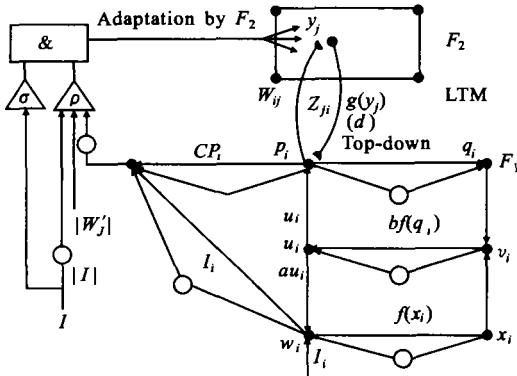


图 5 采用新的调整子系统的 ART-2 网络结构图

Fig. 5 ART-2 network architecture using the new adaptation system

在该算法中,新的检验条件为:

$$\|\rho\| \times t + \frac{\beta_c}{\|X_k\| - \|W'_j(k-1)\| + \beta_c} (1-t) \geq \rho_c, \quad 0 \leq t \leq 1 \quad (13)$$

$$\sigma_T = \sqrt{\frac{1}{n_j + 1} \left(\sum_{i=1}^{n_j} \|X_j(i) - W_T\|^2 + \|X_k - W_T\|^2 \right)} \leq \sigma_c \quad (14)$$

采用这一检验条件具有两个优点:

(1) 由于幅度检验条件的加入,可以很好地修正 ART-2 算法幅度丢失的缺点。

(2) 一般情况下,模式的相位和幅度信息是模式最为重要的特征,但在具体应用中这两种信息的重要性又有所不同,为了反映这一特性,给出了综合这两方面信息的检验条件公式(13),且引入了可调参量 t 用于调节两者比重。当 $t=1, \sigma_c$ 取值足够大时,该式退化为原调整子系统和谐振条件,它适合于只对模式的相位信息感兴趣的应用;当 $0 \leq t < 1$ 时,综合考虑了模式的幅度和相位信息,且随着 t 取值的不同,这两方面信息在检验条件中所占的比重随之改变。

下面给出 $W'_j(k)$ 和 $\sigma(k)$ 的计算公式,由于两种

改进算法的引入,新的 ART 网络增加了 $W'_j(k)$ 和 $\sigma(k)$ 两个量。在用计算机实现时,如果按照它们的定义即 $W'_j = \left(\sum_{i=1}^{n_j} X_j(i) + X_k \right) / (n_j + 1)$ 和 $\sigma_j =$

$\sqrt{\frac{1}{n_j + 1} \left(\sum_{i=1}^{n_j} \|X_j(i) - W'_j\|^2 + \|X_k - W'_j\|^2 \right)}$ 来计算,则需要记录所有先前学习或识别过的样本,这在具有大量样本的应用中将对计算机的计算量和存储量提出较高要求,因而使改进算法的实用性受到影响。事实上,可以利用根据当前样本输入之前第 j 类的 W'_j, σ_j 及 n_j 值,由数理统计中期望和方差的性质递推计算而得新的 W'_j, σ_j ,因此只需记录 ART-2 网络中第 j 类样本的 W'_j, σ_j 及 n_j 值,这种计算量和存储量都是极其有限的。

4 实验结果

模拟生成了 5 组服从正态分布的二维样本数据共 $5 \times 200 = 1000$ 个,其样本的聚类中心分别为 (6, 6), (9, 9), (12, 12), (15, 15), (18, 18)。将这 5 组样本分别以模值从小到大顺序和随机顺序输入原 ART-2、参考文献[6]改进算法、文中的改进算法 1 和改进算法 2 中进行实验,实验结果如表 1 和表 2 所示。

表 1 随机输入样本数据实验结果

Tab. 1 Experimental result by feeding samples

	Original ART-2	Algorithm proposed by ref. [6]	Improved algorithm 1	Improved algorithm 2	
				$t=0.2$	$t=0.8$
Correction rate	<50%	76.5%	92.4%	88.7%	93.4%

表 2 顺序输入样本数据实验结果

Tab. 2 Experimental result by feeding samples sequentially in ascending order of sample norm

	Original ART-2	Algorithm proposed by ref. [6]	Improved algorithm 1	Improved algorithm 2	
				$t=0.2$	$t=0.8$
Correction rate	<50%	46.5%	91.5%	87.7%	93.1%

各参数取值为: $c=0.1, d=0.9, \rho_c=0.9, \beta_c=1.3, \sigma_c=1$ 。实验中原 ART-2 的分类效果最差, 实际上, 它根本就无法把 5 类样本有效地分开。参考文献[6]中的算法则在样本顺序输入的情况下性能显著变差。而文中所提出的两种改进算法表现出了良好且稳定的性能。

5 结 论

ART-2 神经网络广泛地应用于模式识别中的聚类问题, 但是它在处理数据时存在着丢失模式幅度信息的缺点。在详细分析参考文献[6]改进算法缺陷的基础上, 提出了两种改进的 ART-2 算法, 改进算法通过加入一个幅度限定子系统或修正调整子系统的检验条件, 有效地利用了模式的幅度信息。文中的改进算法实际上是原 ART-2 算法的加强, 当改进算法 1 中 β_c 和 σ_c 取足够大, 改进算法 2 中 t 和 σ_c 分别取零和足够大时, 它们即为原 ART-2 算法。另外, 由于两种改进算法中分别需要确定 β_c, σ_c 和 β_c, σ_c, t , 因此它们能较好地应用于具有一定样本幅度先验知识的实际问题中, 但在不具备样本幅度先验知识的应用中, 需要进行多次实验以确定各参数良好的取

值范围或者进一步研究如何自适应确定各参数的方法, 而这种方法的研究, 将成为我们的后续工作。

参考文献:

- [1] Carpenter G A, Grossberg S. A massively parallel architecture for a self-organizing neural pattern recognition machine[J]. Comp Vision Graphics and Image Process, 1987, 37(1): 54-115.
- [2] Carpenter G A, Grossberg S. ART-2: self-organization of stable category recognition codes for analog input pattern[J]. App Optics, 1987, 26(23): 4919-4930.
- [3] Carpenter G A, Grossberg S. ART-3: hierarchical search using chemical transmitters in self-organizing pattern recognition architectures[J]. Neural Networks, 1990, 3(2): 129-152.
- [4] Carpenter G A, Grossberg S, Rosen D B. ART-2A: an adaptive resonance algorithm for rapid category learning and recognition [J]. Neural Networks, 1991, 4: 493-504.
- [5] 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.
- [6] 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.
- [7] 任广升, 李东平, 孙智刚, 等. 楔横轧三维变形光塑性模拟研究 [J]. 吉林工业大学学报, 1992, 22(2): 86-915.

(上接第 100 页)

库函数则由 1394 驱动程序基础上开发的 IO 库函数包装而成。WDM 作为微软 WINDOWS 2000 及后续版本的新驱动模型, 支持 PNP, 可以兼容所有的 WINDOWS 操作平台。所以, 本项目的软件利用 WDM 程序设计技术, 以提高驱动程序的移植性^[5]。

4 结 论

利用 NI 公司和 HP 公司多种 VXI 总线消息基和寄存器仪器, 对设计的 1394/VXI 零槽控制器进行了大量的性能和功能的测试, 测试结果表明, 该 1394/VXI 零槽控制器符合 1394 总线和 VXI 总线规范相关的软硬件技术规范^[1,6,7], 能满足 VXI 总线综合自动化测试系统集成应用开发的需要。

参考文献:

- [1] 姜汉龙译. FIREWIRE 系统体系[M]. 北京: 中国电力出版社出版, 2001.
- [2] 陈光禹. VXI 总线测试平台技术[M]. 成都: 电子科技大学出版, 1996.
- [3] 王岳环, 汪国有, 李巍, 等. VXI 总线消息基器件的研制[J]. 红外与激光工程, 2000, 29(1): 37-39.
- [4] 奚全生, 孟汉城. VXI 总线测试系统[M]. 北京: 宇航出版社, 1992.
- [5] Chris Cant. WINDOWS WMD 驱动程序开发指南[M]. 北京: 机械工业出版社, 2001.
- [6] GB/T 18471-2001, VXI 总线系统规范[S].
- [7] VXIbus Mainframe Extender Specification, VXI-6 Revision 1.0. [M] VXIplug&Play Systems Alliance Published, 1991.