

改进的 ART2 型神经网络在故障诊断中的应用

陆爽,朱建鸿,彭力

LU Shuang,ZHU Jian-hong,PENG Li

江南大学 通信与控制工程学院,江苏 无锡 214122

School of Communication and Control Engineering,Jiangnan University,Wuxi,Jiangsu 214122,China

E-mail:shuanglu1998@163.com

LU Shuang,ZHU Jian-hong,PENG Li.Improved ART2 neural network algorithm for fault diagnosis.Computer Engineering and Applications,2010,46(9):212-214.

Abstract: This paper indicates the shortage of standard ART2 neural network.A simplified ART2 network structure is presented to enhance speed of network performance.The simplified network avoids the different results of standard ART2 neural network because of inputting different sequences.And the paper uses a new method to compute similarity.In order to solve the pattern excursion problem of ART2 neural network,it indicates enabled depth to avoid the problem.It improves the applicative effect of ART2 neural network.

Key words: Adaptive Resonance Theory(ART2);system identification;fault diagnosis

摘要:针对传统 ART2 型神经网络的缺点,提出了一种增强了网络执行速度的改进的 ART2 型神经网络。改进后的算法避免了传统 ART2 因输入次序不同而导致的输出结果不同的缺陷。应用了一种新的方法计算输入模式与所有模式的相似度。为了解决传统 ART2 型神经网络的模式漂移问题引入了激活深度的概念。改善了 ART2 型神经网络的适用性。

关键词:自适应谐振理论 2(ART2);系统辨识;故障诊断

DOI:10.3778/j.issn.1002-8331.2010.09.060 文章编号:1002-8331(2010)09-0212-03 文献标识码:A 中图分类号:TP391

1 绪论

自适应谐振理论(ART)体系结构是一种实现识别任意序列输入模式的识别编码的稳定自组织的一种神经网络系统。ART 首次出现于自适应编码结构正向信道的固有不稳定性分析中,是一种无监督学习方式,包含 ART1,ART2,ART3^[1]。它是一种很好的聚类运算法则,能够满足记忆和学习之间的平衡从而完成动态聚类及快速学习。应用这种方法能够实现学习与应用模式的同时执行。这个模型是针对以往使用较广泛的智能系统应用神经网络范例中所面临的系统的稳定性和可塑性之间的矛盾。可塑性与稳定性使用的道具是密切相关的。自适应系统的特征是能够在稳定性与可塑性模型之间自适应转换,它为了学习新的知识能够维持可塑性,同时在相应不相关和重复时间时能够保持稳定。

ART 网络模型是一种能够学习复杂的连续有效输入模式种类的自组织结构。ART2 神经网络在聚集无序输入模式的任意序列非常有效。它的存储器容量可以通过增加学习模式的方法来增长。网络不仅允许离线学习而且在线同步学习也可以,而且学习和应用状态是不可分的。这种模型不需修改以达到最优化。通过自训练,ART2 可以学习新的东西,解决新问题。同时,它可以针对熟悉的模式采取快速、敏捷的响应。

2 标准 ART2 网络

ART2 网络接受直接来自于模拟载体的输入向量,并将它指派到与输入向量最为匹配的类中。然后进行警惕试验以确定输入向量是否符合期望。如果输入向量通过测试,它将成为该类的一个成员,而后更新与选定类相关的权重以便之后更好地辨识这个类。如果输入向量未通过测试,则产生新的类,使用此输入向量作为最初的范例。

2.1 ART2 网络结构

ART 网络基本结构涉及三组神经元:输入处理单元($F1$ 层),聚类单元($F2$ 层)和重置单元。 $F1$ 层次由两部分组成:输入单元及接口单元。接口单元将来自于输入单元和 $F2$ 层的信号结合起来,以比较输入信号和聚类单元权值向量的相似性。基本结构是如图 1 所示。输入和接口层 $F1$ 的 6 个子层如图 1 所示。每个子层有相同数目的处理单元以及相同大小的特征向量,这些子层的目的是使 ART2 网络处理连续变化的输入。此外,它们使特征向量的组成部分规则化并降低噪声。聚类层 $F2$ 包含两个处理单元,前者只有当与真实签名相应的特征向量出现在网络输入端的时候才是活动的,后者则在其他情况活动。

2.2 ART2 网络原理

在应注意的子系统($F1$ 和 $F2$ 层),一种输入模式 X 首先在

基金项目:国家自然科学基金(the National Natural Science Foundation of China under Grant No.60973095);华中科技大学“数字制造装备与技术”国家重点实验室开放课题。

作者简介:陆爽(1986-),女,硕士,研究方向为模式识别与智能系统;彭力(1967-),男,教授,研究方向为无线传感器网络,人工智能。

收稿日期:2008-09-22 修回日期:2008-12-16




图1 ART2 网络结构图

F1 层表示,其中包含 6 种单元,通过 Z,U,P,S,V 和 Q 细胞。然后经历激励过程,包括规则化,噪声抑制和更新。这导致来自 F1 层的一种输出模式。对应此输出模式,通过从下至上的权值在 F2 层进行激活。由于 F2 层是一个采用获胜者获得一切的竞争层,只有一种存储模式是被保留下来。它也表示了与来自 F1 层输入模式最匹配的模式。此外,F2 层的激励模式产生输出模式,通过从上至下的权值送回 F1 层。

$$X=(x_1, x_2, \dots, x_N) \quad (1)$$

在 F1 层,规则化和非线性函数的结合来执行对比度增强,噪声抑制和重整。为实现不同程度的对比度增强和噪声抑制,使用以下两个非线性函数方程(2)~(3)。

$$f(x)=\begin{cases} \frac{2\theta x^2}{x^2+\theta^2}, & 0 \leq x < \theta \\ x, & x \geq \theta \end{cases} \quad (2)$$

连续可微,或者

$$f(x)=\begin{cases} 0, & 0 \leq x < \theta \\ x, & x \geq \theta \end{cases} \quad (3)$$

线性。在 F1 层的多层的迭代转换之后,根据式(4)计算总的过滤后的从 F1 到第 j 个 F2 神经元的输入:

$$T_j = \sum_{i=1}^N \rho_i w_{ij}, j=1, 2, \dots, M \quad (4)$$

其中 ρ_i 是 F1 层模式 P 的第 i 个元素。从 F1 到 F2 的转换是一个自适应过滤操作。到 F2 层的输入模式通过 F2 层神经元之间的相互作用来转化。在相互作用的对比增强的过程中,F2 的层选择如下接收最大输入的神经元:

$$T_j = \max\{T_j\}, j=1, 2, \dots, M \quad (5)$$

然后一种导向子系统计算 F1 层 P 和 U 两种模式之间的匹配程度。模式 U 是稳定的输入模式,而模式 P 是一个通过一系列的转化计算出的模式。匹配程度由 r_i 给出

$$r_i = \frac{u_i + c p_i}{e + \|U\| + \|cP\|}, i=1, 2, \dots, N \quad (6)$$

其中 $c > 0$ 。如果匹配程度没有达到一个预先指定的阈值 ρ ,即 $\|R\| < \rho$,则该定向子系统重置获胜节点。

因此, w_{ij} 和 w'_{ij} 是 ART2 学习过程的核心部分。这个过程修改获胜神经元的值以使它们更加紧密地代表输入模式。获胜神经元的修改根据以下方程进行:

$$w'_{ij}(t+1) = w_{ij}(t) + g[y_j(t)] [p_i(t) - w_{ij}(t)], i=1, 2, \dots, N; j=1, 2, \dots, M \quad (7)$$

$$w_{ij}(t+1) = w_{ij}(t) + g[y_j(t)] [p_i(t) - w_{ij}(t)], i=1, 2, \dots, N; j=1, 2, \dots, M \quad (8)$$

其中,如果第 j 个神经元没有在当前试验的时候重置,则 $g[y_j(t)]$ 等于常数 d。否则等于 0。换言之,只有与顶端获胜神经元相关的权值才在学习周期被更新。

3 改进的 ART2 网络

3.1 简化的 ART2 网络结构

为了抑制噪音 ART2 网络有两个正反馈。然而,U 神经元和 S 神经元的值是其初始化或最后计算得出的值。这些值和下一个输入信息基本没有联系,但有时这些值和输入信息有关。这样,不同的输入序列将产生不同的类似数值和不同的聚类结果。因此,通过删除两个正反馈来简化图 2 中给出的标准 ART2 网络从而解决它所带来的问题。




图2 简化的 ART2 网络结构图

在聚类问题中,神经网络通常取决于输入数据的属性,因此特征选择对于模式识别系统是很重要的。图 2 中的预处理层完成输入模式 X0 的标准化。

$$x_i = \frac{x_{0i}}{\|X0\|}, i=1, 2, \dots, N \quad (9)$$

在 F1 阶段里有两个神经元模式:

$$S=(s_1, s_2, \dots, s_N), P=(p_1, p_2, \dots, p_N)$$

神经元 S 是习的输入模式与上层返回到下层的权值间的误差信号。神经元 P 同标准 ART2 网络中具有相同的功能。当神经元在 F2 阶段里竞争取得胜利时,神经网络会取出错误信号来计算相似度。

$$s_i = \begin{cases} x_i - \sum_{j=0}^M g(y_j) w'_{ij}, & \|W'_i\| \neq 0 \\ x_i, & \|W'_i\| = 0 \end{cases} \quad (10)$$

$$p_i = ax_i + ds_i, i=1, 2, \dots, N \quad (11)$$

当存在输入模式时 a 和 d 值置 1。所有的权值 w_{ij} 和 w'_{ij} 初始值为 0。

3.2 改进的相似度判定

ART2 网络标准在网络训练前必须指定出它的警戒门限参数,而门限参数的选取直接影响到网络聚类结果。当警戒参数高时,细微差别的不同都可以使识别层重置产生更多的聚类,而警惕参数低时,网络对输入的差别不敏感,因此,产生较少的类。

所以,类结果取决于一个合适的界线。实际应用中太多或是太少的分类都不能够被接受。ART 神经网络警戒参数的设定由于缺少先验的数据库所带来的主观性,并不能完全地避免这个问题,而主观性应该尽可能地适合。有 3 种方法可以用来计算相似度。可以计算 r_i 模,然后通过等式(12)来获得 R1 的模,同样也可以通过等式(13)可以获得 R2 的模^[2]。通过求出两

组向量的欧式距离来表示相似度,可以由等式(14)计算出 R_3 的模^[3]。

$$r_i = \frac{x_i + cP_i}{1 + \|cP\|}, i=1, 2, \dots, N \quad (12)$$

$$r_i = \left(\frac{x_i + p_i}{2}\right)^2, i=1, 2, \dots, N \quad (13)$$

$$R_3 = \exp(-\|X-P\|) \quad (14)$$

以下面三组向量为例:

$$I_1 = (1, 2, 3, 4, 5), I_2 = (5, 6, 7, 8, 9)$$

$$I_3 = (1, 2, 3, 4, 6)$$

可以发现在表 1 中 R_3 的结果更适合于人类的思维。 R_1 和 R_2 的结果都很相似。通过以上分析,改进的 ART2 网络相似度计算方法选择 R_3 。

表 1 计算相似性的 3 种方法的比较表

相似性	R1	R2	R3
I_2 和 I_1	0.998 13	0.989 15	0.886 66
I_3 和 I_1	0.999 74	0.998 45	0.955 52

3.3 改进的权值调整方法

标准的 ART2 运算法则的另一个问题是在学习期间会转换聚类标本,一个标本向量被新的输入向量所替代,一个变化的标本可能导致未来运行中的不适宜的聚类,这叫做模式漂移^[4-5]。使用激活深度可以避免这类问题。

这样,公式(11)可转换为:

$$p_i = (1 - d_{j^*})x_i + d_{j^*}(x_i - w_{ji}'), i=1, 2, \dots, N \quad (15)$$

当输出神经元 j^* 从所有神经元获胜, $depth_{j^*}$ 将加 1, 而其他加 0, 变量 d_{j^*} 定义为:

$$d_{j^*} = \frac{depth_{j^*}}{depth_{j^*} + 1}, j=1, 2, \dots, M \quad (16)$$

$depth_{j^*}$ 等于在 F2 层由 j^* 输出神经元习得的输入模式的值。

$$d_j = \begin{cases} d_{j^*}, & j=j^* \\ 0, & j \neq j^* \end{cases}, j=1, 2, \dots, M \quad (17)$$

更新的标准与标准的 ART2 网络相似,但变化的程度将依照激活的深度不同。

$$w_{ij^*}(t+1) = \begin{cases} d_{j^*} w_{ij^*}(t) + (1 - d_{j^*})x_i, & \|W_i\| \neq 0 \\ x_i, & \|W_i\| = 0 \end{cases} \quad (18)$$

$$w_{ji}'(t+1) = w_{ij^*}(t+1) \quad (19)$$

4 讨论

为了阐述改善 ART2 网络的性能,以雷达喇叭设备控制继电器范例,把 ART2 网络故障诊断性能与改善 ART2 网络的相比较,在表 2 中,有一些错误的数字,那些数据是现场原始数据,可以按模糊的方法处理它们如表 3,标准训练使用了模糊方法来区别数据。

$$f(x) = e^{-k(x-b)^2} (k > 0) \quad (20)$$

b 是一个参数,代表正常状态下的值。

表 2 原始故障类型表

NO.	V_1	V_2	V_3	V_4	V_5	故障
1	11.264	14.134	10.631	14.779	11.331	y_1 (正常)
2	0.171	14.780	0	14.780	0.248	y_2 (R_1 断路)
3	11.234	10.465	10.452	10.881	10.882	y_3 (R_2 断路)
4	11.264	14.134	10.833	14.779	11.536	y_4 (R_3 断路)
5	10.264	14.180	14.757	14.780	13.355	y_5 (R_4 断路)
6	0.741	14.653	0.153	14.780	0.002	y_6 (短路)
7	10.341	14.780	9.512	14.780	9.973	y_7 (BG_1 开集)
8	11.264	14.780	9.989	14.780	10.689	y_8 (BG_1 集电极和发射极断路)
9	11.333	11.341	12.305	13.020	13.012	y_9 (BG_1 基极和集电极短路)
10	11.264	14.058	14.058	14.776	14.767	y_{10} (BG_1 集电极和发射极短路)

K 为调整过的参数。不同的测试点采用不同的调整值, $k_1=10, k_2=0.3, k_3=2.5, k_4=0.2, k_5=1$ 。

由于 ART2 网络的几点不足,它较难区分出正常与故障模式。然而采用改进的 ART2 网络,能区分表 4 中不同次序输入的不同结果,并且这种改进的 ART2 网络能够更好地区分错误类型。当灵敏值设为 0.995 时,能从 10 种类型中分辨出 9 种类型的错误。

表 4 改进的 ART2 型网络与 ART2 型的故障诊断比较表

ART2 网络				改进的 ART2 网络			
閾值 0.99	閾值 0.995	閾值 0.95	閾值 0.99	閾值 0.99	閾值 0.95	閾值 0.99	閾值 0.99
顺序	倒序	顺序	倒序	顺序	倒序	顺序	倒序
y_1	y_{10}	y_1	y_{10}	y_1	y_4	y_1	y_{10}
y_1	y_{10}	y_1	y_9	y_2	y_3	y_2	y_9
y_2	y_{10}	y_2	y_9	y_3	y_1	y_3	y_8
y_3	y_{10}	y_3	y_9	y_1	y_1	y_1	y_7
y_3	y_{10}	y_4	y_9	y_4	y_2	y_5	y_6
y_3	y_{10}	y_4	y_9	y_2	y_4	y_6	y_5
y_3	y_{10}	y_4	y_9	y_1	y_1	y_7	y_1
y_3	y_{10}	y_4	y_9	y_1	y_3	y_8	y_3
y_3	y_{10}	y_4	y_9	y_3	y_2	y_9	y_2
y_3	y_{10}	y_4	y_9	y_4	y_1	y_{10}	y_1

在表 5 中有两组测试用的原始数据,而在表 6 中是模糊处理过的数据。这些测试数据是用来检测网络的正确性用的,测试上述网络的结果放在表 7 中。分析可以发现模糊数据比原始数据显示出了更强的优势,并且前者的灵敏值可以选得更小一点。

表 5 测试原始数据类型表

NO.	V_1	V_2	V_3	V_4	V_5
(1)	11.330	11.331	12.305	13.002	13.012
(2)	11.260	14.778	14.747	14.780	13.315

表 6 模糊测试数据类型表

NO.	x_1	x_2	x_3	x_4	x_5
(1)	0.957 4	0.094 7	0.000 9	0.538 6	0.059 3
(2)	0.999 8	0.883 0	0	1.000 0	0.016 6

5 结论

基于上述理论的分析,提出了一种 ART2 神经网络以及其

表 3 模糊故障数据类型表

NO.	1	2	3	4	5	6	7	8	9	10
x_1	1.000 0	0	0.991 0	1.000 0	1.000 0	0	0.002 0	1.000 0	0.952 5	1.000 0
x_2	1.000 0	0.882 3	0.017 6	1.000 0	0.882 3	0.922 3	0.882 3	0.882 3	0.096 3	0.998 3
x_3	1.000 0	0	0.923 0	0.903 0	0	0	0.043 7	0.356 9	0.000 9	0
x_4	1.000 0	1.000 0	0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	0.538 6	1.000 0
x_5	1.000 0	0	0.817 4	0.958 8	0.007 1	0	0.158 2	0.662 3	0.059 3	0

(下转 223 页)