

一种新的 FART 分类器

雷洪利, 张殿治, 刘文华, 严盛文
(空军工程大学 工程学院, 陕西 西安 710038)

摘要:提出了一类基于贴近度理论的模糊 ART 神经网络模型, 简称为 CBFART(Closeness Based Fuzzy ART)模型。将模糊数学中的贴近度(Closeness)和择近原则(Closest Principle)概念与自适应共振理论(ART)相结合, 形成了一种新的网络模型。该模型的学习以匹配—委托循环为特点, 网络分类遵循择近原则。补码编码、匹配—委托和快速委托—慢速重编码方案相结合, 保证了网络学习的收敛性和稳定性, 并可以做到一次性学习, 提高了学习速度。文中对高维样本进行分类仿真, 给出了仿真结果, 分析表明该模型具有良好的聚类特性, 能够稳定地对高维样本进行分类。

关键词:神经网络; 自适应共振理论; 模糊; 贴近度; 择近原则

中图分类号:TP389.1; O235 **文献标识码:**A **文章编号:**1009-3516(2002)01-0064-04

Grossberg 于 1976 年提出自适应共振理论以来, Carpenter 和 Grossberg 等人已经相继提出和改进了一族基于这一理论的自组织竞争网络模型, 包括 ART1, ART2, ART2-A, ART3 和 FART^[1-5]。这些模型算法的工作机理与模式识别中的聚类分析算法有相似之处, 但又有它们自身的特点。每一种网络的分类和学习都以某种距离度量作为依据, 通过警戒参数 ρ 来设定分类标准。其动态聚类过程就是根据警戒参数 ρ 所设定的标准, 按照网络所关注的特征判断输入样本间的相似程度, 从而对样本集进行划分。这里存在两个问题: 第一, 由于网络只根据样本集的某种特征分类^[6], 它就必然要忽略样本集的其他特征, 所以聚类结果不仅取决于被聚类样本的维数和特征, 还取决于网络的分类机制; 第二, 网络的适用范围受到分类机制的限制, 只有在网络所关注的样本特征是样本集的主要特征时, 网络聚类才能获得理想的结果, 否则, 分类的可靠性就不高。此外, 在网络学习过程中缺少监督机制, 主要表现在每一个样本输入时, 不论它属于还是不属于已存在的类别, 网络都要进行一次扫描, 这就势必造成学习时间的延长。

CBFART 模型将贴近度和择近原则与 ART 模型结合, 根据样本间靠近的程度, 按照择近原则对样本集进行划分, 引入了全新的分类机制。它选取最大最小值贴近度作为 F2 层信号函数, 使网络的聚类更侧重于样本集的综合特征, 拓宽了网络的适用范围。通过以匹配—委托方式取代上述 ART 系列网络的匹配—复位—扫描机制, 删除了不必要的扫描过程和 2/3 规则, 提高了网络的学习速度。同时, 将增益控制器改为委托脉冲发射器, 以保证这一学习机制的实施。仿真结果证明了网络结构的设计和分类机制的确立是合理的, 从收敛性和分类稳定性上看都能满足要求。

1 贴近度、择近原则和模糊模式识别

1.1 贴近度

根据贴近度^[7]的公理化定义, 在新模型中采用 $\max - \min$ 运算, 构造贴近度, 即

$$N(\bar{A}, \bar{B}) = \frac{\sum_{i=1}^n (\mu \bar{A}(x_i) \wedge \mu \bar{B}(x_i))}{\sum_{i=1}^n (\mu \bar{A}(x_i) \vee \mu \bar{B}(x_i))} \quad (1)$$

式中, \vee 为模糊或 (\max) 算子; \wedge 为模糊与 (\min) 算子; μ 为隶属度。

1.2 择近原则

择近原则^[7]: 设 $\bar{A}_1, \bar{A}_2, \dots, \bar{A}_n \in F(U)$ 为 n 个标准模糊模式, $\bar{B}_n \in F(U)$ 为待识别对象, 若有 $i \in \{1, 2, \dots, n\}$ 使

$$N(\bar{A}_i, \bar{B}) = \max\{(\bar{A}_1, \bar{B}), \dots, N(\bar{A}_n, \bar{B})\} \quad (2)$$

则认为 \bar{B} 与 \bar{A} 最为靠近。

择近原则是 CCBART 网络分类机制的基础。

2 网络结构与编码过程

CCBART 模型是在 ART 系列模型的基础上演化而来, 它保留了 ART 系列模型的一些特点, 同时结合了新的成分。与 ART 系列网络的匹配—复位—扫描过程不同, CCBART 模型采用匹配—委托方式进行编码和学习, 使其编码过程成为一次性学习, 提高了学习速度。

2.1 网络结构

具体的 CBFART 结构参见文献[7], 该模型结构的特点在于匹配—委托循环上, 在这里, 增益控制器变成一个委托脉冲发射器。当 F2 层反馈信号向量 V 到达 F1 层之后, F1 层在向量 V 和当前输入向量 I 的共同作用下, 产生一个控制委托脉冲发射器的信号 σ , 即

$$\sigma = N(I, V) \quad (3)$$

式中, $N(\dots)$ 代表贴适度函数。当满足

$$\sigma \geq \rho \quad (4)$$

时, 则输入与所选中模板匹配, 进入学习状态; 否则, 增益控制器将发出一个委托脉冲, 选择 F2 层中下标最小的未受委托节点作为当前样本的类型标志, 进入学习状态。可见, 这里面省去了复位—扫描过程, 而且网络也不遵守 2/3 原则, 但匹配—委托机制保证了网络学习的收敛。

2.2 网络编码过程

2.2.1 信号编码

1) 预处理。CBFART 网络处理的是补码编码之后的样本。通常, 原始数据经过模糊化过程会丢失信息, 有时丢失的信息还是原始数据的关键特征, 这就引入了人为的差错。补码编码过程可以弥补模糊化过程中数据信息的丢失, 是一种有效的方法。

假设模糊化之后的初始输入向量为:

$$A = \{a_1, \dots, a_m\} \quad (5)$$

A 的每个元素都取区间 $[0, 1]$ 内的值。则补码编码之后得到 FO 层输入为

$$I = \{A, A^c\} = \{a_1, \dots, a_m, 1 - a_1, \dots, 1 - a_m\} \quad (6)$$

补码编码使得网络输入变为 $2M$ 维。

2) F1 层信号。F1 层各节点输入输出满足

$$X_i = I_i, (i = 1, \dots, 2M) \quad (7)$$

当 F2 层有信号返回时, F1 层产生一个控制委托脉冲发射器的信号 σ ,

$$\sigma = N(I, V) = \sum_{i=1}^{2M} (I_i \wedge W_{ji}) / \sum_{i=1}^{2M} (I_i \vee W_{ji}) \quad (8)$$

式中, V 为被选中模板向量, \wedge 表示 \min 算子, \vee 表示 \max 算子。

3) F2 层激励。①输入信号函数。CBFART 模型的主要特点是, F2 层第 j 个节点的净输入 T_j 为当前输入 I 和模板向量 W_j 的贴适度, 即

$$T_j = N(I, W_j) = \sum_{i=1}^{2M} (I_i \wedge W_{ji}) / \sum_{i=1}^{2M} (I_i \vee W_{ji}) \quad (j = 1, \dots, N) \quad (9)$$

②F2 层编码。在 F2 层, 网络按 WTA (winner - take - all) 规则^[1-5] 进行编码, 即

$$y_j = \begin{cases} 1 & j = J \\ 0 & i \neq J \end{cases} \quad (10)$$

式中, J 为接收到最大净输入 $T_j = \max\{T_j, j = 1, \dots, N\}$ 的 F2 层节点对应下标。③F2 层反馈信号。当输入 I

激活一个 F2 层代码之后,在 F2→F1 的路径上将反馈回一个信号向量

$$V \cdot V = W_j \quad (11)$$

2.2.2 网络匹配—委托过程

CBFART 网络的编码学习机制与 ART 系列相比有较大改进。由于 F2 层第 j 个节点接收到的净输入信号为当前输入 I 和模板 W_j 的贴进度,而按照 WTA 规则,F2 层接收到最大净输入的节点 J 获胜,同时增益控制器的控制信号即为最大贴进度,这相当于将当前样本按照择近原则进行分类。网络的匹配—委托过程描述如下:当一个样本 I 输入网络后,通过网络的前向信号通道(底层—往上滤波器^[1,4-5]),在 F2 层输入端形成一个经模板矩阵滤波得到的净输入向量 T ,该向量各元素为当前输入和 F2 层各节点对应模板之间的贴进度。按照 WTA 编码规则,F2 层接收到最大净输入,即对应贴进度最大的节点 J 获胜,于是网络激活一个 F2 层代码 Y 。紧接着在 F2→F1 路径产生一反馈信号向量 V ,F1 层检测到该信号后,在当前输入 I 和反馈信号 V 的作用下,就产生一个控制委托脉冲发射器的脉冲信号,脉冲峰值为 $\sigma = N(I, V)$,它对应 F2 层净输入中的最大贴进度值,因此,若它不满足匹配判据

$$\sigma \geq \rho \quad (12)$$

则其它 F2 层节点对应模板也不满足此判据。这样,网络的学习过程就可以省去复位—扫描过程,当获胜节点不满足匹配判据时,委托脉冲发射器直接给 F2 层发送一委托脉冲,选中一下标最小的未受委托节点作为当前输入的类型标志,进入学习状态。对于满足匹配判据的情形,网络发生共振。

同时网络学习采用快速委托—慢速重编码方案^[1,3,5],在初始状态下,权值全部取为 1。当网络进入学习状态后,权值按照下式进行调整

$$W_j^{(new)} = W_j^{(old)} + \beta \times (I - W_j^{(old)}) \quad (13)$$

若 J 为未受委托节点,则 $\beta = 1.0$,此时网络处于快速学习状态,学习结果网络建立了一个新的类别;否则, β 取 $[0, 1]$ 内的小数,网络处于慢速学习状态,学习结果网络将当前输入中的新信息结合到模板中,从而使模板向“聚类中心”移动。

CBFART 网络的信号规则和学习机制保证了网络能够进行稳定学习和分类,其 F2 层节点数应视输入样本数和警戒参数 ρ 而定,通常应有一定余量。

3 模拟仿真结果

采用文献[7]CBFART 网络算法,对网络在高维数据下进行仿真,用文献[6]样本集,由 100 个不同的模式组成 100 维,经补码编码之后维数达到 200 维,进行 10 次学习,并给出聚类结果及其各聚类中心曲线。

这里用二阶系统阶跃响应曲线作为数据样本集。响应函数是归一化的,以便满足网络输入要求,同时使振荡结果收敛到 0.5 附近,具体函数表达式如下,

$$\begin{aligned} f(t) &= 0.5 \times [1 - e^{-\zeta \cdot w_0 \cdot t} \times (\cos g(t) + c \times \sin g(t))] \\ g(t) &= w_0 \times \sqrt{1 - \zeta^2} \times t \\ c &= \frac{\zeta}{\sqrt{1 - \zeta^2}} \end{aligned} \quad (14)$$

式中, ζ 为阻尼因子; w_0 为角频率。网络输入向量由 $f(t)$ 当 $t = 1, 2, \dots, 100$ 时的 100 个连续采样点组成,按照 ζ 和 w_0 的不同取值选取 100 个样本。阶跃响应有一个特性,它只由本征频率 $f_0 = w_0/2\pi$ 和阻尼因子 ζ 这两个物理参数决定。取 $N = 10, \rho = 0.8, \beta = 0.01$,经过 10 次学习,结果如图 1 所示。此时网络分类已达到稳定,即使再增加学习次数,也不发生变化,但聚类中心会继续调整。将 β 置 0,使网络进入识别状态,识别结果正确率达到 100%,说明网络分类很理想,形成的聚类中心完全可以作为各类样本的代表。




图 1 高维样本聚类结果

4 结论

CBFART 模型根据样本间贴近的程度,按照择近原则对样本集进行聚类。选取最大—最小值贴近度作为 F2 层的输入信号函数,使网络处理的信息为一种综合信息,克服了 FART 模型分类时只注意到不同样本间共同的“min”分量和 ART2 模型单纯只根据角度特征分类的不足^[1,4-6]。匹配—委托机制的引入,省去了学习过程中不必要的扫描,节约了时间,使学习速度得到较大提高。与前面二维数据的仿真结果相比,要达到相同的正确率,FART 网络至少要对样本集进行 5 次以上的学习而 CBFART 只需一次学习,其模型不仅可用于模式识别,而且可用于系统辨识。

参考文献:

- [1] GARPENTER G A. Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system[J]. *Neural Networks*, 1991,4:759 - 771.
- [2] GARPENTER G A. A massively parallel architecture for a self - organizing neural pattern recognition machine[A]. *Computer Vision Graphics, and Image Processing*, 1987,37:54 - 115.
- [3] GARPENTER G A. ART 2: Self - organization of stable category recognition codes for analog input patterns[M]. *Applied Optics*, 1987 26:4919 - 4930.
- [4] GARPENTER G A. ART 3: Hierarchical search using chemical transmitters in self - organizing pattern recognition architecture. [J]. *Neural Networks*, 1990,3:129 - 152.
- [5] GARPENTER G A. ART 2 - A: An Adaptive Resonance Algorithm for Rapid Category Learning and Recognition[J]. *Neural Networks*, 1991,4:493 - 504.
- [6] FRANK T. Comparative Analysis of Fuzzy ART and ART - 2a Neural Network Clustering Performance[J]. *IEEE Trans on Neural Networks*, 1998,9(3):544 - 559.
- [7] 刘文华,雷洪利,张殿治. Closeness Theory Based Fuzzy ART Model[A]. 第三届全国华人控制年会论文集[C]. 合肥:中国科技大学出版社,2000.

(编辑:姚树峰)

A New Cluster Based Fuzzy ART Model

LEI Hong - li, ZHANG Dian - zhi, LIU Wen - hua, YAN Sheng - wen

(The Engineering Institute, Air Force Engineering University, Xi'an 710038, China)

Abstract: A new fuzzy ART neural network model based on closeness theory, called CBFART for short, is introduced in this paper. The new network model is formed by incorporating the two concepts of fuzzy set theory, closeness and closest principles, with adaptive resonance theory (ART). The learning of the model is characterized by matching - consigning cycle, and the classification of patterns in the network conforms to the closest principle. Coding complement, matching - consigning, and fast consigning - slow recoding procedure work together to make sure that learning of the network is converging and stable. The above three elements also make one shot learning practicable, so as to improve the learning speed of the network. The concrete algorithm of the model and the result of simulation are given in the paper, and the analysis shows that the model is good in clustering performance.

Keywords: neural network; adaptive resonance theory; fuzzy; closeness; closest principle