

基于ART的RBF网络结构设计

蒙西, 乔俊飞, 韩红桂

(北京工业大学 电子信息与控制工程学院, 北京 100124)

摘要: 针对径向基函数(RBF)网络隐层结构难以确定的问题, 基于自适应共振理论(ART)网络良好的在线分类特性, 提出一种RBF网络结构设计算法. 该算法将ART网络的聚类特性用于RBF网络结构设计中, 通过对输入向量与已存模式的相似度比较将输入向量进行分类, 确定隐含层节点个数和初始参数, 使网络具有精简的结构. 对典型非线性函数逼近的仿真结果表明, 所提出的结构具有快速的学习能力和良好的逼近能力.

关键词: 自适应共振理论网络; 径向基函数神经网络; 结构设计

中图分类号: TP273

文献标志码: A

RBF Neural network based on ART neural network

MENG Xi, QIAO Jun-fei, HAN Hong-gui

(College of Electronic Information and Control Engineering, Beijing University of Technology, Beijing 100124, China. Correspondent: QIAO Jun-fei, E-mail: junfeiq@bjut.edu.cn)

Abstract: For the problem that it is difficult to determine the hidden layer structure of the radial basis function(RBF) neural network, based on the good online classified characteristic of adaptive resonance theory(ART) neural network, a self-organizing RBF neural network structure design algorithm is proposed. The algorithm uses the clustering characteristic of ART neural network to design the RBF neural network structure. Through the similarity comparison of input vector, the number of the hidden layer nodes and initial parameters are determined, so that the network has simplified structure. The experiment results show that the proposed structure has a smaller number of nodes, fast learning speed and better approximation ability.

Key words: adaptive resonance theory(ART) network; radial basis function(RBF) network; structure design

0 引言

径向基函数(RBF)神经网络因为其结构特性具有良好的非线性映射能力, 与其他前馈型神经网络相比, 具有较快的收敛速度且不易陷入局部极小. 因此, 径向基网络被广泛用于非线性系统建模与控制、模式识别等领域^[1-2], 但RBF网络的结构设计却是一个开放性问题^[3]. 许多学者就RBF网络的结构设计问题展开了研究, 试图寻求一种合适的方法来确定RBF网络隐含层节点的个数及参数, 其中RBF神经网络结构动态优化设计是当前的研究热点^[4], 主要有增长法、修剪法和增长修剪法.

Platt^[5]提出一种增长型资源分配网络(RAN)模型, RAN能够根据处理对象增加隐含层神经元个数, 以达到处理复杂信息的目的, 但RAN容易出现网络

结构过大的问题. 为了解决RAN结构出现冗余的问题, 在RAN的基础上, Yingwei等^[6]引入修剪法, 提出了一种最小资源神经网络(MRAN), MRAN不仅实现了隐含层神经元的自适应增长, 而且还通过删减策略对网络隐含层节点个数进行删减. 但是, MRAN在结构调整后未对参数进行相对应的调整, 网络学习时的收敛速度较慢. 因此在对RAN和MRAN改进的基础上, Huang等^[7]提出了一种增长修剪型RBF神经网络(GGAP-RBF), GGAP-RBF通过判断隐含层神经元的重要性来决定对隐含层神经元的增减. 但是, GGAP-RBF需要参考总体样本数据来设定网络初始值, 因此该方法不适用于没有预先给出所有样本的情况. Han等^[8]提出了一种自组织RBF神经网络(SORBF), SORBF通过对隐层RBF神经元接受野半

收稿日期: 2013-07-11; 修回日期: 2013-10-15.

基金项目: 国家自然科学基金项目(61034008, 61203099, 61225016); 北京市自然科学基金项目(4122006); 教育部博士点新教师基金项目(20121103120020).

作者简介: 蒙西(1988—), 女, 博士生, 从事智能控制与智能信息处理、复杂过程建模与优化控制的研究; 乔俊飞(1968—), 男, 教授, 博士生导师, 从事智能控制与智能信息处理、复杂过程建模与优化控制等研究.

径的判断实现结构的自适应增删, 实验证明 SORBF 网络具有良好的逼近效果, 但该算法中涉及的参数较多, 在一定程度上会影响网络的性能。

自适应共振理论 (ART) 神经网络是 Grossberg 于 1986 年提出的。ART 网络是基于生物机制建立的人工神经网络, 具有自组织聚类分析的功能, 能对相同特征的事物进行自组织分类^[9]。又因为 RBF 神经网络隐节点的设计可以转化为聚类问题, 所以有学者基于 ART 神经网络的聚类特性来确定 RBF 神经网络的隐节点。Dac 等^[10]基于 ART2 网络的聚类特性确定 RBF 神经网络的隐层节点个数和初始中心值, 但由于未确定初始宽度和初始权值两个重要参数, 网络的训练时间较长。因为直接用 ART 神经网络进行聚类提高了神经 RBF 神经网络的复杂性, Lee 等^[11]基于 ART 网络的思想将样本进行聚类, 得到 RBF 神经网络的初始结构。实验表明该网络具有较好的性能, 但该网络的隐层传递函数选取的是改进的核函数, 与经典的高斯函数相比, 增加了新的参数; 同时, 在进行样本分类时, 进行了两次比较, 引入了两个不同的警戒参数, 因此导致网络中参数过多。

基于以上问题, 本文提出一种新的基于 ART 思想的 RBF 神经网络。首先利用 ART 的分类思想, 通过一次相似度比较确定 RBF 网络的初始结构及相应的初始参数; 然后利用梯度下降法进行学习; 最后的仿真实验表明, 基于本文思想所设计出的结构, 与其他网络相比, 结构简单、学习速度快、泛化能力好。

1 RBF 神经网络

RBF 网络是一个典型的 3 层前馈型神经网络, 由输入层、隐含层、输出层组成。输入层接收外界的信息传递给隐含层, 隐含层对接收的信息进行整合映射, 输出层是线性层, 为作用于输出层的激活信号提供响应。设 RBF 网络结构为 $n-j-m$ (n 个输入节点, j 个隐层节点, m 个输出节点), 其网络结构如图 1 所示。




图 1 RBF 网络结构图

图 1 中 $x = (x_1, x_2, \dots, x_n)^T$ 为网络输入向量, 隐含层节点个数为 j , 隐层传递函数为径向基函数, 常选用标准的高斯函数, 即

$$\Phi_j(x) = e^{-\frac{\|x - c_j\|^2}{\sigma_j^2}}. \quad (1)$$

其中: c_j 为第 j 个节点的中心向量, σ_j 为第 j 个节点的宽度。则第 m 个节点的输出为

$$y_m = \sum_{j=1}^J w_{jm} \Phi_j, \quad (2)$$

w_{jm} 为第 j 个隐层节点到第 m 个输出节点的连接权值。

确定网络结构后, 通过学习算法对隐节点中心向量及扩展宽度、隐层到输出层连接权值进行调整。

2 基于 ART 的 RBF 网络设计

RBF 网络的设计包括结构设计和学习算法选择两部分。对 RBF 网络结构的设计即为对隐含层节点个数和初始参数的确定, 这个问题可以转换为聚类问题, 即寻求一种合适的聚类方法来确定隐含层节点个数和初始参数。

在确定网络初始结构的基础上, 接下来需要寻求一种合适的学习算法对网络进行学习训练, 以使网络达到期望的性能。

2.1 网络结构设计

ART 网络能对相同特征的事物进行自组织分类。当有新的模式进入网络时, 会与已经存储的模式进行比较, 如果新模式与既有的一类模式相似度较高时, 则可以归为已有的一类; 如果新模式与既有的模式不相似, 则需要在网络中建立一个新的模式类。当对所有的样本比较结束后即完成模式分类。因此, 可以利用 ART 神经网络的自组织分类功能来确定 RBF 网络隐含层节点个数及初始参数。

基于 ART 的 RBF 网络通过对向量进行相似度比较来完成分类, 相似度公式^[12]表示如下:

$$s(x_i, c_j) = 1 - \frac{\text{dist}(x_i, c_j)}{\|x_i\| + \|c_j\|}. \quad (3)$$

其中: x_i 为第 i 个输入向量, c_j 为第 j 个节点的中心向量, $\text{dist}(x_i, c_j)$ 为向量 x_i 与向量 c_j 之间的欧几里得距离, $\|x_i\|$ 和 $\|c_j\|$ 分别为向量 x_i 和 c_j 的长度, 相似度 $s(x_i, c_j) \in [0, 1]$ 。

由式 (3) 可得: 当 $x_i = c_j$ 时, 有

$$s(x_i, c_j) = 1, \quad (4)$$

即第 i 个输入向量与第 j 个隐节点的中心向量完全相同, x_i 与 c_j 相似度最高; 当 $x_i = -c_j$ 时, 有

$$s(x_i, c_j) = 0, \quad (5)$$

即第 i 个输入向量与第 j 个隐节点的中心向量距离最低, x_i 与 c_j 相似度最低。

设网络的训练样本是由 N 个输入输出对 (x, y_d) 组成, 其中 x 为 n 维输入向量, y_d 为相对应的 m 维期

望输出, 隐含层节点个数为 J . 初始时刻, 网络隐含层的节点数为 0. 当第 1 个数据样本进入网络后, 将输入向量作为第 1 个隐节点的中心向量, 将输出向量作为隐节点到输出层的连接权值.

在 k 时刻, 假设已经存在 j 个隐节点, 即当第 k 个数据样本进入网络时, 需要对第 k 个输入向量与已存在的 j 个隐节点的中心向量的相似度进行比较, 比较公式如下:

$$s(x_k, c_j) = 1 - \frac{\text{dist}(x_k, c_j)}{\|x_k\| + \|c_j\|}. \quad (6)$$

由式 (6) 可知, x_k 与 c_j 越相似, $s(x_k, c_j)$ 的取值越大, 则第 k 个数据样本越有可能激活第 j 个隐节点. 找出 $s(x_k, c_j)$ 中的最大值, 设

$$s_{\max}(x_k, c_j) = s(x_k, c_l), \quad (7)$$

即现有的 j 个隐节点中, 第 l 个隐节点与第 k 个输入向量的相似度最大. 下面分以下两种情况进行讨论:

1) 隐节点调整. 当 $s(x_k, c_l) \geq V$ 时, 认为第 l 个隐节点与第 k 个输入向量的相似度足够大, 当前网络能够对新数据进行学习, 只需要对第 l 个隐节点的参数进行相应调整, 即

$$c_l = \frac{c_l + x_k}{2}, \quad (8)$$

$$w_l = \frac{w_l + y_{dk}}{2}. \quad (9)$$

V 为警戒参数, 可以控制网络的分类力度, 当 V 较大时, 分类精度较高; 当 V 较小时, 分类精度较低. 在实验中, V 为预先给定的常数, 根据不同的实验要求, V 的取值不同.

2) 隐节点增加. 当 $s(x_k, c_l) < V$ 时, 认为第 k 个输入向量不能激活现有的任何一个隐节点, 因此需要增加一个新的隐节点来对第 k 个数据样本进行学习, 即

$$J = j + 1, \quad (10)$$

$$c_{j+1} = x_k, \quad (11)$$

$$w_{j+1} = y_{dk}. \quad (12)$$

综上, 可得到基于 ART 的 RBF 网络结构设计算法如下.

Step 1: 初始时刻, 网络中没有隐含层节点.

Step 2: 当第 1 个数据进入网络后, 为网络分配 1 个隐含层节点, 同时将第 1 个数据的输入向量赋予第 1 个隐节点作为其中心向量; 将第 1 个期望输出向量作为第 1 个隐节点到输出节点的连接权值.

Step 3: 当第 k 个数据进入网络后, 计算第 k 个数据的输入向量与当前所有隐节点的中心向量相似度, 找出第 k 个输入向量相似度最大的隐节点 l .

Step 4: 若满足隐节点增加准则, 则为网络新增

加一个隐节点, 并给新的隐节点赋予初始参数, 如式 (10)~(12) 所示, 转向 Step 3; 否则, 执行下一步.

Step 5: 按式 (8) 和 (9) 所示, 对第 l 个隐节点的参数进行相应调整. 转向 Step 3.

该算法将 ART 网络机制用于 RBF 网络隐层节点的确定, 为 RBF 网络寻求了一个精简的结构, 并且得到的初始参数有利于提高网络在学习训练中的速度.

2.2 网络学习算法

在网络初始结构确定后, 需要对网络权值及隐节点参数进行学习调整. 性能目标函数选用均方误差函数, 即

$$E = \frac{1}{2} \sum_{p=1}^N (y_{dp} - y_p)^2. \quad (13)$$

采用梯度下降法对权值及参数进行调整, 直到达到期望精度为止. 对隐层到输出层的连接权值 w_{jn} 、高斯函数的中心向量 c_j 、高斯函数的宽度 σ_j 进行如下调整:

$$w_{jn}(k+1) = w_{jn}(k) - \eta_w \frac{\partial E(k)}{\partial w_{jn}(k)}, \quad (14)$$

$$\frac{\partial E(k)}{\partial w_{jn}(k)} = - \sum_{p=1}^{P_N} (y_{dp} - y_p) \varphi_j(x_p), \quad (15)$$

$$c_j(k+1) = c_j(k) - \eta_c \frac{\partial E(k)}{\partial c_j(k)}, \quad (16)$$

$$\begin{aligned} \frac{\partial E(k)}{\partial c_j(k)} = & - \frac{1}{\sigma_j^2} \sum_{p=1}^{P_N} \sum_{n=1}^N (y_{dp} - y_p) w_{jn}(k) \times \\ & \varphi(x_p) [x_p - c_j(k)], \end{aligned} \quad (17)$$

$$\sigma_j(k+1) = \sigma_j(k) - \eta_\sigma \frac{\partial E(k)}{\partial \sigma_j(k)}, \quad (18)$$

$$\begin{aligned} \frac{\partial E(k)}{\partial \sigma_j(k)} = & - \frac{1}{\sigma_j^3} \sum_{p=1}^{P_N} \sum_{n=1}^N (y_{dp} - y_p) w_{jn}(k) \times \\ & \varphi(x_p) \|x_p - c_j(k)\|^2. \end{aligned} \quad (19)$$

3 仿真实验

为了检验基于 ART 的自组织 RBF 网络的非线性映射能力, 选取两个典型的非线性函数进行逼近.

3.1 非线性函数 sin E 逼近

对非线性函数 sin E 进行逼近, 有

$$y = 0.8 \exp(-0.2x) \sin(10x). \quad (20)$$

随机选取 200 个样本对网络进行训练, 201 个样本对网络进行测试, 期望误差为 0.01, 警戒参数设定为 0.65. 函数逼近效果如图 2 所示, 学习性能曲线如图 3 所示.




图 2 函数逼近效果




图 3 学习性能曲线

由图 2 可以看出, ART-RBF 网络经过学习训练后能够很好地逼近非线性函数 $\sin E$, 期望输出曲线与实际输出曲线基本能达到重合. 通过对迭代次数的跟踪, 由图 3 可知, 本文提出的网络收敛速度较快, 在第 300 步时基本能达到完全收敛.

此外, 为了体现 ART-RBF 网络比其他网络结构的性能更好, 将 ART-RBF 网络的函数逼近结果与其他算法的结果^[8,13-14]进行了比较, 比较结果如表 1 所示.

表 1 实验结果对比

网络类型	运行时间/s	测试误差	隐节点数
RAN	62.32	0.0673	25
GAP-RBF	26.86	0.0415	19
ART-RBF	13.86	0.0137	14

由以上结果可知: 与其他网络结构相比, 本文提出的 ART-RBF 网络隐层结构更为精简, 隐节点数要少于其他网络; 因为隐层节点数较少, 初始参数随着隐节点数的确定也相应确定, 所以 ART-RBF 网络的运行速度较快; ART-RBF 网络的测试误差较小, 逼近效果也优于其他网络.

3.2 墨西哥草帽函数逼近

三维墨西哥草帽函数是难度较大的近似问题^[15]. 本文用 ART-RBF 网络对其进行逼近, 函数形式如下:

$$f(x_1, x_2) = \sin(\sqrt{x_1^2 + x_2^2}) / (\sqrt{x_1^2 + x_2^2}), \quad (21)$$

其中 $x_1, x_2 \in [-2\pi, 2\pi]$.

仿真时, 在 $[-2\pi, 2\pi]$ 区间上随机产生 600 个输入样本和 400 个测试样本, 警戒参数设定为 0.6. 图 4 所示为测试样本的理想输出效果图, 图 5 所示为经过学习训练后的 ART-RBF 网络对测试样本的逼近效果图.




图 4 理想输出




图 5 ART-RBF 网络实际输出

由图 5 可以看出, 经过学习的 ART-RBF 网络能够很好地逼近墨西哥草帽函数, 拟合曲面很好地逼近了期望输出, 拟合效果较为理想.

网络最终的隐层节点数为 33, 由此可以看出在墨西哥草帽函数的逼近问题上, ART-RBF 网络结构较为精简. 此外, ART-RBF 网络在逼近墨西哥草帽函数时的运行时间为 57.238 s, 在运行时间方面具有一定的优势. 由此表明, 基于 ART 的 RBF 网络能够较好地解决墨西哥草帽函数逼近问题.

4 结 论

本文将基于视觉机制建立的 ART 网络用于 RBF 网络构建中, 利用 ART 的在线聚类特性自适应调整隐层节点个数并得到网络的初始参数. 通过对典型非线性函数 $\sin E$ 和墨西哥草帽函数的逼近, 表明了基于 ART 机制建立的 RBF 网络与其他网络相比, 结构更精简, 逼近效果更好, 运行时间更快.

虽然 ART-RBF 网络在函数逼近方面取得了较好的效果, 但仍需进一步研究和探讨:

- 1) ART 网络的优势在于在线聚类, 可以为 ART-RBF 网络寻求一种在线学习算法, 使网络具有更好的实用性;
- 2) 相似度、警戒参数与隐层节点宽度之间具有一定的数学关系, 有待进一步证明以提高网络的性能.

参考文献(References)

[1] Chen S, Wolfgang A, Harris C J, et al. Symmetric RBF classifier for nonlinear detection in multiple-antenna-aided

- systems[J]. IEEE Trans on Neural Networks, 2008, 19(5): 737-745.
- [2] 乔俊飞, 韩红桂. RBF神经网络的结构动态优化设计[J]. 自动化学报, 2010, 36(6): 865-872.
(Qiao J F, Han H G. Optimal structure design for RBFNN structure[J]. Acta Automatica Sinica, 2010, 36(6): 865-872.)
- [3] Xabier Barandiaran, Alvaro Moreno. On the nature of neural information: A critique of the received view 50 years later[J]. Neurocomputing, 2008, 71(4/5/6): 681-692.
- [4] 乔俊飞, 韩红桂. 神经网络结构动态优化设计的分析与展望[J]. 控制理论与应用, 2010, 27(3): 350-357.
(Qiao J F, Han H G. Dynamic optimization structure design for neural networks: Review and perspective[J]. Control Theory and Applications, 2010, 27(3): 350-357.)
- [5] Platt J. A resource-allocating network for function interpolation[J]. Neural Computation, 1991, 3(2): 213-225.
- [6] Yingwei L, Sundararajan N, Saratchandran P. A sequential learning scheme for function approximation using minimal radial basis function(RBF) neural networks[J]. Neural Computation, 1997, 9(2): 461-478.
- [7] Huang G B, Saratchandran P, Sundararajan N. A generalized growing and pruning RBF(GGAP-RBF) neural network for function approximation[J]. IEEE Trans on Neural Networks, 2005, 16(1): 57-67.
- [8] Han H G, Chen Q L, Qiao J F. Research on an online self organizing radial basis function neural network[J]. Neural Computing Application, 2010, 19(5): 667-676.
- [9] Carpenter G A, Grossberg S. The ART of adaptive pattern recognition by a self-organizing neural network[J]. Computer, 1988, 21(3): 77-88.
- [10] Dae Y L, Byung M K, Hyung S C. A self-organized basis function network combined with ART II[C]. Proc of IEEE Int Joint Conf on Neural Networks. Washington, DC: IEEE, 1999: 1963-1968.
- [11] Lee S J, Hou C L. An ART-based construction of RBF networks[J]. IEEE Trans on Neural Networks, 2002, 13(6): 1308-1321.
- [12] Fu L, Yang M, Braylan R, et al. Real-time adaptive clustering of flow cytometric data[J]. Pattern Recognition, 1993, 26(2): 365-373.
- [13] Huang G B, Saratchandran P, Sundararajan N. An efficient sequential learning algorithm for growing and pruning RBF(GAP-RBF) networks[J]. IEEE Trans on System, Man, Cybern B, 2004, 34(6): 2284-2292.
- [14] Keem Siah Yap, Chee Peng Lim, Abidi I Z. A hybrid ART-GRNN online learning neural network with a ε -insensitive loss function[J]. IEEE Trans on Neural Networks, 2008, 19(9): 1641-1646.
- [15] 张昭昭, 乔俊飞, 杨刚. 一种功能分区的BP神经网络结构设计方法[J]. 控制与决策, 2011, 26(11): 1659-1664.
(Zhang Z Z, Qiao J F, Yang G. Structure model of function-dividing design for BP neural network[J]. Control and Decision, 2011, 26(11): 1659-1664.)

(责任编辑: 孙艺红)