

模糊神经网络的结构自组织算法及应用

乔俊飞, 王会东

(北京工业大学 人工智能与机器人研究所, 北京 100022)

摘要: 提出了一种新的模糊神经网络自组织算法, 该算法能够基于输入输出数据自动进行结构辨识和参数辨识. 首先采用一种自组织聚类方法建立起网络的结构和各参数的初值, 然后采用监督学习来优化网络参数. 通过对非线性函数逼近的分析, 证明了该自组织算法的有效性, 并与其他算法作了比较. 最后, 以某污水处理厂的运行数据为对象, 应用该模糊神经网络建立了活性污泥系统出水水质预测模型, 仿真结果表明, 该模型能够对污水处理系统出水水质进行较好的预测.

关键词: 自组织; 模糊神经网络; 预测模型; 污水处理

中图分类号: TP273 **文献标识码:** A

Structure self-organizing algorithm for fuzzy neural networks and its applications

QIAO Jun-fei, WANG Hui-dong

(Institute of Artificial Intelligence and Robotics, Beijing University of Technology, Beijing 100022, China)

Abstract: A new self-organizing algorithm for fuzzy neural networks is proposed, which automates the structure and parameter identification simultaneously based on input-target samples. Firstly, a self-organizing clustering method is used to establish the network structure and the initial values of its parameters. Then a supervised learning is applied to optimize these parameters. An example of nonlinear function approximation is given to demonstrate the effectiveness of the algorithm, where some comparisons are made with other approaches. Finally, based on the data of a wastewater treatment plant, a forecast model of the output-water quality is developed using the established fuzzy neural networks. Simulation results show that the output-water quality can be well predicted by the model.

Key words: self-organizing; fuzzy neural networks; forecast model; wastewater treatment

1 引言(Introduction)

模糊神经网络融合了模糊推理的知识表达能力和神经网络的自学习能力, 在自适应控制、自适应信号处理、非线性系统辨识和模式识别等领域得到了广泛的应用^[1~5].

模糊神经网络的设计包括结构辨识和参数辨识, 结构辨识包括输入空间的划分和模糊规则数的确定. 传统的输入空间划分方法采用格栅法划分, 即输入变量为 m 个, 每个变量的模糊论域数为 n 个, 则模糊规则数为 n^m 个. 这种划分方法主要存在两个缺陷: 一是输入空间的划分数需要根据经验事先给定, 网络结构在学习过程中保持不变, 容易造成模糊规则的欠缺或冗余; 二是对于复杂系统, 随着输入变量数的增加, 模糊规则数成指数级增长, 从而带来维数灾难^[2]. 采用基于聚类的方法对输入空间进行划分, 在

系统性能相同的前提下可以大大减少模糊规则数^[6].

本文基于聚类思想提出了一种自组织模糊神经网络算法, 该算法能够基于输入输出数据自动调整网络结构和参数, 进而实现模糊规则的自动生成和调整.

2 模糊神经网络的结构(Structure of fuzzy neural networks)

不失一般性, 考虑一个多输入单输出的模糊系统, 该系统模型包含 L 条模糊规则, 其中第 k 条($1 \leq k \leq L$)规则为

R_k : If x_1 is A_1^k and $\cdots$ and x_n is A_n^k , then y_k .

$x = \{x_i\}_{i=1, \dots, n}$ 是输入变量, y_k 是结论变量, A_i^k 是输入变量的隶属函数, 取高斯函数, 即

$$\mu_{ik}(x_i) = \exp\{-(x_i - c_{ik})^2 / \sigma_{ik}^2\}. \quad (1)$$

收稿日期: 2006-06-11; 收修改稿日期: 2007-06-26.

基金项目: 国家自然科学基金资助项目(60304012, 60674066); 北京市优秀人才培养项目(2006D0501500203); 国家863计划项目(2007AA04Z160).

c_{ik}, σ_{ik} 分别为高斯函数的中心值和宽度.

本文中模糊神经网络的拓扑结构如图1所示, 由4层组成:

第1层为输入层, 此层的各神经元直接与输入变量相连接.

第2层为模糊化层, 这一层的节点被分为 L 组, 每一组代表一条模糊规则的前件部分, 每一节点用来计算输入变量的隶属度值 $\mu_{ik}(x_i)$.

第3层为模糊推理层, 采用乘积推理, 计算每条模糊规则的激励强度:

$$\mu_k(\mathbf{x}) = \prod_{i=1}^n \mu_{ik}(x_i). \quad (2)$$

第4层为清晰化层, 计算网络输出值 y :

$$y = \frac{\sum_{k=1}^L \mu_k(\mathbf{x}) w_k}{\sum_{k=1}^L \mu_k(\mathbf{x})}. \quad (3)$$

1,2层以及2,3层之间的连接权值均为1. w_k 为3,4层之间的连接权值, 对应结论变量 y_k .




图1 模糊神经网络的拓扑结构

Fig. 1 Architecture of fuzzy neural networks

传统的模糊神经网络, 输入变量划分的论域数需要根据经验事先给定, 而对于不同的问题对象, 缺乏一个行之有效的指导原则, 因而很难得到输入变量论域数的最佳划分, 往往造成模糊规则数的欠缺或冗余; 同时, 对于复杂的多输入变量系统, 传统的划分方法面临着维数灾难的瓶颈问题.

为解决上述问题, 本文提出了一种模糊神经网络自组织算法.

3 模糊神经网络的自组织算法(Self-organizing algorithm for fuzzy neural networks)

自组织算法包括模糊神经网络的结构自组织设计和参数优化学习两部分. 整个学习过程中假定存在一个由 P 组 $n+1$ 维输入—输出样本组成的数据集:

$$S = \{z_p = (\mathbf{x}_p, \hat{y}_p)\} = \{(x_{p1}, x_{p2}, \dots, x_{pm}), \hat{y}_p\}_{p=1,2,\dots,P}.$$

3.1 模糊神经网络的结构自组织设计(Structure self-organizing design for fuzzy neural networks)

为了得到简洁的网络结构, 本文在RPCL(rival penalized competitive learning)算法^[7]的基础上, 提出了一种新的聚类算法对输入空间进行划分, 该算法可以在学习的过程中自动调整聚类数目, 从而对输入空间进行灵活划分, 得到最佳的模糊规则数. 首先构建一个模糊神经网络的初始结构, 在学习过程中删除一些节点和连接, 从而得到最终的网络结构.

具体算法步骤如下:

Step 1 随机选取 L_0 个样本点作为初始聚类中心 $\{c_k\}_{k=1,2,\dots,L_0}$, 设定删除节点的阈值 ξ , 收敛判据的初值 $h = 0$, 聚类中心数 $L = L_0$;

Step 2 设置计数器 $t = 1$ 和最大学习次数 T , 从数据集 S 中随机选择一个样本 z_p , 计算

$$d(z_p, c_k) = \gamma_k \|z_p - c_k\|, \quad k = 1, 2, \dots, L, \quad (4)$$

$\gamma_k = n_k / \sum_{k=1}^L n_k$, n_k 是节点 k 获胜累计次数;

Step 3 确定获胜神经元 w 和竞争对手神经元 r :

$$d(z_p, c_w) = \min_k d(z_p, c_k), \quad (5)$$

$$d(z_p, c_r) = \min_{k \neq w} d(z_p, c_k); \quad (6)$$

Step 4 修改神经元 w 和神经元 r 的权值向量, 其他神经元权值向量保持不变,

$$c_w = c_w + \alpha_w(t)(z_p - c_w), \quad (7)$$

$$c_r = c_r - \alpha_r(t)(z_p - c_r). \quad (8)$$

$\alpha_w(t), \alpha_r(t)$ 为神经元 w 和神经元 r 的学习率:

$$\alpha_w(t) = \alpha_{w0}(1 - t/T), \quad (9)$$

$$\alpha_r(t) = \alpha_{r0}(1 - t/T). \quad (10)$$

α_{w0}, α_{r0} 为学习率初值, $0 \leq \alpha_{r0} \leq \alpha_{w0} \leq 1$;

Step 5 $t = t + 1$, 如果 $t \leq T$, 则转向Step 2, 否则转向Step 6;

Step 6 对于每个样本, 找出离它最近的聚类中心, 并归入相应的类;

Step 7 计算每类包含的样本数, 如果与总样本数之比小于阈值 ξ , 则删除该类(节点), $L = L - 1$; 如果没有节点被删除, 则 $h = h + 1$;

Step 8 如果 $h = 2$, 停机; 否则转向Step 2.

自组织学习阶段完成后, 产生了 L 个聚类中心 $(c_1, \dots, c_k, \dots, c_L)$, $c_k = (c_{1k}, c_{2k}, \dots, c_{nk}, w_k)$, 从而确定了每条规则的前件部分中各高斯函数的中心值 $\{c_{ik}\}_{i=1, \dots, n}$ 和后件参数 w_k . 获得了高斯函数的中心值后, 高斯函数的宽度可由 N 近邻启发算法计算得到

$$\sigma_{ik} = \frac{|c_{ik} - c_{ih}|}{r}, \quad (11)$$

c_{ih} 表示 c_{ik} 最近的值, r 为交迭参数, 取值范围 $[1.0, 2.0]$.

由此, 通过自组织学习阶段, 可以获得模糊神经网络的结构(规则数)和参数初值(规则的前件、后件参数).

3.2 模糊神经网络的优化学习(Optimization learning for fuzzy neural networks)

建立起模糊神经网络的结构之后, 以自组织学习阶段获得的参数值作为监督学习阶段网络的初值, 基于同一训练集合, 采用变学习率、加入动量项的改进BP算法将各参数值调整到最优, 从而得到模糊神经网络的最终模型.

根据式(3), 从集合 S 中任取一个输入样本 $\mathbf{x}_p$, 网络的输出为

$$y_p = \frac{\sum_{k=1}^L \mu_k(\mathbf{x}_p) w_k}{\sum_{k=1}^L \mu_k(\mathbf{x}_p)}. \quad (12)$$

设误差函数为

$$E = \frac{1}{2} \sum_{p=1}^P (y_p - \hat{y}_p)^2, \quad (13)$$

$$\frac{\partial E}{\partial c_{ik}} = \frac{\partial E}{\partial y_p} \frac{\partial y_p}{\partial \mu_k} \frac{\partial \mu_k}{\partial c_{ik}} = (y_p - \hat{y}_p) \left(\frac{w_k - y_p}{\sum_{k=1}^L \mu_k(\mathbf{x}_p)} \right) \mu_k(\mathbf{x}_p) \frac{2(x_{pi} - c_{i,k})}{\sigma_{ik}^2}. \quad (14)$$

令

$$\delta_1 = \frac{y_p - \hat{y}_p}{\sum_{k=1}^L \mu_k(\mathbf{x}_p)}, \quad (15)$$

$$\delta_1 = \delta_1 (w_k - y_p) \mu_k(\mathbf{x}_p), \quad (16)$$

则 $c_{i,k}$ 的更新公式为

$$\Delta c_{i,k} = -\eta \sum_{p=1}^P \frac{\partial E}{\partial c_{ik}} = -\eta \sum_{p=1}^P \delta_2 \frac{2(x_{pi} - c_{i,k})}{\sigma_{ik}^2}. \quad (17)$$

类似地, 可得到 $\sigma_{i,k}, w_k$ 的更新公式:

$$\Delta \sigma_{i,k} = -\eta \sum_{p=1}^P \frac{\partial E}{\partial \sigma_{ik}} = -\eta \sum_{p=1}^P \delta_2 \frac{2(x_{pi} - c_{i,k})}{\sigma_{ik}^3}, \quad (18)$$

$$\Delta w_k = \eta \sum_{p=1}^P \frac{\partial E}{\partial w_k} = -\eta \sum_{p=1}^P \delta_1 \mu_k(\mathbf{x}_p), \quad (19)$$

$$i = 1, \dots, n, p = 1, \dots, P, k = 1, \dots, L.$$

4 仿真实验(Simulations)

为验证本文所提出的模糊神经网络自组织算法的有效性, 本节给出了两个仿真实例. 首先给出一个函数逼近的例子, 通过与其他算法的比较分析, 证明了该算法的优越性. 随后, 将该算法应用于一个实际的污水处理系统, 建立了污水处理系统的出水水质预测模型, 仿真结果证明了该预测模型的有效性.

4.1 3输入非线性函数逼近(Function approximation of three-input nonlinear function)

为便于比较, 选用一个典型的3输入非线性函数逼近的例子^[2,8,9]:

$$f = (1 + x^{0.5} + y^{-1} + z^{-1.5})^2. \quad (20)$$

216个训练数据和125个检验数据分别从输入空间 $[1, 6] \times [1, 6] \times [1, 6]$ 和 $[1.5, 5.5] \times [1.5, 5.5] \times [1.5, 5.5]$ 中均匀采样, 经过3.1节的自组织学习后, 模糊神经网络包含5条模糊规则($L = 5$). 为了比较性能, 网络的优化学习阶段采用平均百分误差作为性能指标^[2]:

$$APE = \frac{1}{P} \sum_{p=1}^P \frac{|y_p - \hat{y}_p|}{|\hat{y}_p|} \times 100\%. \quad (21)$$

P 是样本个数, y_p 和 $\hat{y}_p$ 分别是第 p 个预测输出和期望输出.

图2给出了网络经过200步训练后的训练样本误差曲线. 训练样本和测试样本的实际值和模型输出值如图3所示, 从图中可以看出训练后的网络达到了较高的精度, 并且具有较好的泛化能力.

网络训练后, 3个输入变量的隶属函数分别如图4~6所示.




图2 平均百分误差曲线

Fig. 2 APE during training




图3 样本实际值与模型值的比较

Fig. 3 Comparisons of desired data with model data




图4 x 的隶属函数Fig. 4 Membership functions of input x 图5 y 的隶属函数Fig. 5 Membership functions of input y 图6 z 的隶属函数Fig. 6 Membership functions of input z

表1 SOFNN模型与其他模型的比较

Table 1 Comparisons of SOFNN with other models

模型	$APE_{trn}/\%$	$APE_{chk}/\%$	参数个数	训练数据规模	检验数据规模
GMDH模型 ^[8]	4.7	5.7	—	20	20
OLS模型 ^[9]	2.43	2.56	66	216	125
GDFNN模型 ^[2]	2.11	1.54	64	216	125
SOFNN模型	0.56	2.32	35	216	125

表1列出了本文提出的SOFNN(self-organizing fuzzy neural networks)模型的结果及其他早期工作的结果. 从表中可以看出, 同样的数据规模, SOFNN模型所需要辨识的参数个数明显少于早期的OLS(orthogonal least squares)模型和GDFNN(generalized dynamic fuzzy neural networks)模型, 而且相同的训练步数, 能够取得更高的精度.

4.2 在污水处理系统建模中的应用(Application in modeling the wastewater treatment system)

活性污泥法是目前世界上工业有机废水和城市污水二次处理的主要方法之一. 污水处理工艺过程模拟和控制的关键是建立出水水质的预测模型^[10], 以便根据出水水质指标及时调整运行参数, 使系统处于最佳的运行状态, 发挥最大的处理效能.

影响污水处理效果的因素有很多, 本文选取对

污水处理效果影响较大的COD(化学需氧量)、BOD₅(生化需氧量)、PH值、NH₃-N(氨氮)、SS(悬浮物)等5个进水水质指标作为网络的输入变量, 输出变量为经过活性污泥系统处理后的出水COD^[11]. 以某污水处理厂2003年全年实际运行的污水处理水质日报表数据作为原始数据, 经过剔除异常数据和标准化预处理^[12], 得到330组数据, 选取8月份的30组数据作为测试样本, 其余月份的300组数据作为训练样本.

利用本文提出的自组织模糊神经网络建立污水处理系统出水水质预测模型, 神经网络经过训练后, 训练样本的实际值与模型输出值, 测试样本的实际值与模型输出值分别见图7,8. 从图中可以看出, 该预测模型较好地模拟了活性污泥系统的运行情况, 模型具有较好的泛化能力. 表2列出了训练样本和测试样本的各项性能指标.




图 7 训练样本的实际值与模型输出值

Fig. 7 Desired data and model data of training samples




图 8 测试样本的实际值与模型输出值

Fig. 8 Desired data and model data of testing samples

表 2 训练样本和测试样本的性能指标

Table 2 Performance index of training and testing samples

性能指标	训练样本 模型值(实际值)	测试样本 模型值(实际值)
RMSE	3.7174	3.8712
AAE	2.4282	2.6819
APE/%	3.77	3.98
R	0.9312	0.9025
μ	67.9795(68.0187)	69.1279(68.4533)
σ	7.1172(8.0880)	8.2295(8.8604)
min	54.2210(54.1000)	55.8860(55.2000)
max	86.2109(88.4000)	87.4095(86.5000)

表2中: RMSE为均方根误差, AAE为平均绝对误差, APE为平均百分误差, R 为相关系数, μ 为均值, σ 为标准差, min为最小值, max为最大值。

5 结论(Conclusions)

本文基于聚类算法, 提出了一种自组织模糊神经网络, 其主要特点如下:

- 1) 能够根据输入输出数据自动生成网络结构, 并且能够对网络的参数进行优化学习。
- 2) 能够根据对象的特性, 生成合适的网络

结构。

3) 基于该模糊神经网络建立的污水处理系统出水水质预测模型, 较好的模拟了活性污泥系统的运行情况。

参考文献(References):

[1] ER M J, WU S. A fast learning algorithm for parsimonious fuzzy neural systems[J]. *Fuzzy Sets and Systems*, 2002, 126(3): 337 – 351.

[2] ER M J, WU S, GAO Y. A fast approach for automatic generation of fuzzy rules by generalized dynamic fuzzy neural networks[J]. *IEEE Transactions on Fuzzy Systems*, 2001, 9(4): 578 – 594.

[3] THAWONMAS R, ABE S. Function approximation based on fuzzy rules extracted from partitioned numerical data[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1999, 29(4): 525 – 534.

[4] LENG G, PRASAD G, MCGINNITY T M. An on-line algorithm for creating self-organizing fuzzy neural networks[J]. *Neural Networks*, 2004, 17(10): 1477 – 1493.

[5] MASTOROCOSTAS P A, THEOCHARIS J B. A recurrent fuzzy-neural model for dynamic system identification[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 2002, 32(2): 176 – 190.

[6] ZADEH L A. Soft computing and fuzzy logic[J]. *IEEE Software*, 1994, 11(6): 48 – 56.

[7] XU L, KRZYSAK A, OJA E. Rival penalized competitive learning for clustering analysis, RBF net, and curve detection[J]. *IEEE Transactions on Neural Networks*, 1993, 4(4): 636 – 649.

[8] KONDO T. Revised GMDH algorithm estimating degree of the complete polynomial[J]. *Transactions of the society of Instrument and Control Engineers*, 1986, 22(9): 928 – 934.

[9] CHEN S, COWAN C F N, GRANT P M. Orthogonal least squares learning algorithm for radial basis function network[J]. *IEEE Transactions on Neural Networks*, 1991, 2(2): 302 – 309.

[10] 伊学农, 周琪. 基于改进BP网络与MISO模型的污水系统建模[J]. 水处理技术, 2005, 31(10): 21 – 24.

(YI Xuenong, ZHOU Qi. Modeling of wastewater treatment process based on improved BP network[J]. *Technology of Water Treatment*, 2005, 31(10): 21 – 24.)

[11] 冉维丽, 乔俊飞. 基于PCA时间延迟神经网络的BOD在线预测软测量方法[J]. 电工技术学报, 2004, 19(12): 78 – 82.

(RAN Weili, QIAO Junfei. BOD soft-measuring approach based on PCA time-delay neural networks[J]. *Transactions of China Electrotechnical Society*, 2004, 19(12): 78 – 82.)

[12] 余颖. 活性污泥法污水处理过程智能建模及仿真研究[D]. 北京: 北京工业大学, 2005.

(YU Ying. *Research of intelligent modeling and simulation to activated sludge wastewater process*[D]. Beijing: Beijing University of Technology, 2005.)

作者简介:

乔俊飞 (1968—), 男, 教授, 博士生导师, 主要研究方向为计算智能与智能优化控制、复杂过程建模与优化控制等, E-mail: jun-feiq@bjut.edu.cn;

王会东 (1979—), 男, 2007年6月于北京工业大学获得工学硕士学位, 现为中科院自动化所在读博士研究生, 研究方向为飞行器控制分配、重构飞行控制、智能控制理论及应用, E-mail: huidong.wang@ia.ac.cn.