

Neurofuzzy GMDH Network and Its Application to the Soft-Sensor for Ethene Distillation Process

Yuzhong Li¹ Feng Qian²

1: Institute of Automation, East China University of Science & Technology Shanghai 200237

2: Institute of Automation, East China University of Science & Technology Shanghai 200237

1: E-mail: e_lyz@263.net

Abstract In this paper, a new Neurofuzzy GMDH network for system modelling and prediction is developed. This network introduces the structure of GMDH network into its structure, and its partial descriptions are represented by the Radial Functions network which is equivalent with fuzzy models in the first layer and by N-Adline network in other layers. This method exerts the merits of them. The results of function approximation shows that the NF-GMDH network outperforms the conventional GMDH network. The final example shows that NF-GMDH can be used in Soft-Sensing modelling of the ethene rectification process.

Key words GMDH; NF-GMDH; partial description; soft-sensor

神经模糊 GMDH 网络 及其在乙烯精馏过程软测量中的应用*

李玉忠

(华东理工大学自动化研究所, 上海 200237)

钱锋

(华东理工大学自动化研究所, 上海 200237)

摘要 本文提出了一种模糊 GMDH 网络, 该网络采用 GMDH 网络的结构形式, 在第一层网络节点的局部描述采用模糊模型, 利用 RBF 网络模型在一定条件下与模糊模型的等价性来实现模糊模型, 而其他的各层局部描述采用 N-Adline 网络节点。这样, 充分发挥了模糊模型和 GMDH 网络的优点。本文运用这种网络对一离散函数进行了拟合, 拟合结果表明 NF-GMDH 网络比 GMDH 网络有更好的拟合能力, 最后的仿真实例证明该网络可以用于乙烯精馏过程软测量模型建模。

关键词 数据处理的组方法, 神经模糊 GMDH, 局部描述, 软测量

1. 引言

GMDH (Group Method of Data Handling)^[1] 是由 Ivakhnenko (1968) 提出的一种辨识非线性复杂系统非常有效的数据分析方法, 特别是当可利用的数据较少而输入变量数目较多的时候更加有效。广义来说, 采用这种方法建立的网络统称为 GMDH 网络。GMDH 网络的优点是网络结构是在训练中动态的自我确定, 而不需要事先确定。而且在最初的 GMDH 网络中对已有数据进行了划分, 即将输入输出数据划分为训练数据和选择数据, 训练数据估计

网络结构参数, 选择数据用来选择中间变量, 这样做的规则化处理避免了过拟合。

GMDH 网络提出至今, 许多学者对其进行了丰富和发展。GMDH 网络按其算法可分为两大类: (1) 感知器型; (2) 网络型。对于感知器型 GMDH 网络, 用两个独立的输入变量构成局部描述, 通过选择数据按一定规则来选择局部描述, 选择的局部描述的输出作为下层的输入, 如此反复直到终止规则满足。而与之不同的是 70 年代在美国发展起来的自适应学习网络, 其可以被看作是一种网络型的 GMDH 网络, 此网络中不需要感知器型局部描述的连续选择, 这区别于感知器型 GMDH 网络。

最近几年一种新的 GMDH 网络模型被提出来, 它的局部描述采用 RBF 网络或者模糊模型, 人们称

*基金项目: 国家自然科学基金资助项目 (60074027); 上海市教育发展基金会曙光计划项目 (2000SG18); 国家“十五”863 计划 CIMS 技术主题项目 (2001AA411230)

这种网络模型为神经模糊 GMDH(NF-GMDH)^[2,3]。实际上,NFGMDH也是一种网络型的 GMDH 网络,局部描述采用 RBF 网络是利用了一定条件下 RBF 网络模型与模糊模型的等价性, Brown 和 Harris^[4]证明了模糊模型与 RBF 网络模型在一定条件下存在等价关系,而且它们各自继承了对方的特性。

本文提出了一种类似于上述 NFGMDH 网络的网络模型,其特点是在网络第一层局部描述仍采用 RBF 网络,而其他各层局部描述采用 N-Adline 节点,这样的一种网络充分发挥了 RBF 网络中高斯函数良好的局部特性及 GMDH 多项式网络的全局特性的优点。本文用这种网络对进行了实例仿真,结果表明这种网络模型比 GMDH 网络有更高的辨识精度,最后本文也对石油化工工业乙烯精馏塔塔釜乙烯浓度进行了仿真辨识,辨识结果表明可利用此种网络来辨识过程工业非线性系统模型,因此完全可以用于软测量模型建模。

2. 基于 RBF 网络及 N-Adline 网络的 NF-GMDH 网络

GMDH 网络的思想是根据输入的变量对输入进行分组组合处理,然后根据组合后处理的结果来评价决定网络的最佳结构。由此,本文所提出的 NFGMDH 也采用了这种思想来训练网络和确定网络结构。本文提出的网络结构示意图如图 1 所示。




图 1 神经模糊 GMDH 网络结构示意图

其中,网络中第一层局部描述为 RBF 网络,而其他各层采用 N-Adline 网络。而第一层也可以采用模糊模型,本文采用 RBF 网络的原因是利用了一定条件下 RBF 网络与模糊模型的等价性。

(1) RBF 网络与模糊逻辑系统的等价性

考虑一多输入单输出模糊逻辑系统,其模糊规则集中第 k 条规则可描述如下:

$$R^{(k)}: \text{如果 } x_1 \text{ 为 } X_1^k, \text{ 且 } \dots, \text{ 且 } x_n \text{ 为 } X_n^k \text{ 则 } y \text{ 为 } Y^k; \quad (1)$$

X_i^k 和 Y^k 分别为 $U_i \subset R$ 和 $V \subset R$ 上的模糊集合; $\mathbf{x} = (x_1, \dots, x_n)^T \in U_1 \times \dots \times U_n$ 和 $\mathbf{y} \in V$ 均为语言变量。采用中心平均模糊消除器、乘积推理规则、单值模糊产生器和 x_i 隶属函数用高斯函数表示的上述模糊逻辑系统可表示如下:

$$\bar{y} = \frac{\sum_{k=1}^M \bar{y}^k [\prod_{i=1}^n \exp(-\frac{(x_i - \bar{x}_i^k)^2}{\sigma_i^k})]}{\sum_{k=1}^M \prod_{i=1}^n \exp(-\frac{(x_i - \bar{x}_i^k)^2}{\sigma_i^k})} \quad (2)$$

式中, \bar{x}_i^k 和 σ_i^k 为相应 x_i 的中心和方差。令

$$p_i = \frac{\prod_{i=1}^n \exp(-\frac{(x_i - \bar{x}_i^k)^2}{\sigma_i^k})}{\sum_{k=1}^M \prod_{i=1}^n \exp(-\frac{(x_i - \bar{x}_i^k)^2}{\sigma_i^k})} \quad (3)$$

则上述的模糊逻辑系统可表述为 p_i 的展开式

$$\bar{y} = \sum_{i=1}^M \bar{y}^k p_i \quad (4)$$

如果定义 p_i 为模糊系统的模糊基函数,那么把径向基函数神经网络的基函数与上述模糊系统的基函数比较一下,就可以看出两者是等价的, M.Brown 和 C.Harris 在“Neurofuzzy Adaptive Modeling and control”中证明了两者的等价性。

(2) NFGMDH 网络的学习算法

1) 模糊部分 (RBF 网络) 学习算法

把模糊推理模型第 i 个输入变量 x_i^m 第 k ($k = 1, 2, \dots, K$) 条规则的隶属函数表 μ_{ki}

$$\mu_{ki}(x_i^m) = \exp\left\{-\frac{(x_i^m - a_{ki}^m)^2}{b_{ki}^m}\right\} \quad (5)$$

若采用模糊蕴涵乘积规则,则第 m 个模糊模型的输出 y^m 为:

$$y^m = \sum_{k=1}^K [\prod_{i=1}^n \mu_{ki}(x_i^m)] w_k^m \quad (6)$$

式 (6) 可以看成是一个高斯函数 RBF 网络,它能够以任意精度逼近任一连续映射。最后输出 y 是最后的 P 层的输出均值

$$y = \frac{1}{M} \sum_{m=1}^M y^{pm} \quad (7)$$

设目标值为 y^* ，则误差性能指标可表示为 $E_1 = \frac{1}{2}(y - y^*)^2$ ，学习过程为逐步减少 E_1 的值，学习规则基于 LMS (least mean square) 法，规则可描述如下

$$w_k^{pmNEW} = w_k^{pmOLD} - \tau \mu_k^{pm} \delta^{pm} \quad (8)$$

$$a_{k,i}^{pmNEW} = a_{k,i}^{pmOLD} - \tau \mu_k^{pm} w_k^{pm} \frac{2(x_i^{pm} - a_{k,i}^{pm})}{b_{k,i}^{pm}} \delta^{pm} \quad (9)$$

$$b_{k,i}^{pmNEW} = b_{k,i}^{pmOLD} - \tau \mu_k^{pm} w_k^{pm} \frac{(x_i^{pm} - a_{k,i}^{pm})^2}{(b_{k,i}^{pm})^2} \delta^{pm} \quad (10)$$

其中， τ 为一微小正值， δ^{pm} 为反向传播误差，如果是最后一层，那么 $\delta^{pm} = (y - y^*) / M$ ，如果对于中间层，则

$$\delta^{pm} = 2 \sum_{l=m}^{m+1} \delta^{p+1,l} \times \sum_{q=1}^4 w_q^{p+1,l} \mu_q^{p+1,l} \frac{(y^{pm} - a_{q,r}^{p+1,l})}{b_{q,r}^{p+1,l}} \quad (11)$$

式中，若 $l = m + 1$ ，则 $r = 1$ ，若 $l = m$ ，则 $r = 2$ ，若 $m = M$ ，则 $m + 1 = 1$ 。

以上运算在学习过程中连续叠代，输入输出数据规一化到 $[0,1]$ 范围内。

2) N-Adline 网络学习算法

一个 N-Adline 节点的输出为为输入的多项式组合，可表示为

$$y = w_0 + w_1 x_1 + w_2 x_1^2 + w_3 x_1 x_2 + w_4 x_2^2 + w_5 x_2 \quad (12)$$

其中 X 为节点的两个输入，采用 Widrow-Hoff (Widrow and Lehr 1990) 规则来训练网络的权值，权值调整规则如下

$$W_{k+1} = W_k + \alpha \frac{X_k}{|X_k|^2} (y_k^d - W_k^T X_k) \quad (13)$$

式中， y_k^d 为在 k 步的期望输出， α 为学习系

数，学习过程中叠代修正权值以使网络的输出与期望输出的误差减小。

(3) NFGMDH 网络的学习步骤

NFGMDH 网络学习过程是对输入进行两两组合，并根据局部描述的类型来训练网络，训练直到满足某一指定规则指标结束，然后对各个处理单元的局部描述进行评估，以确定那些局部描述的输入输出进入网络下一层，构筑下一层的网络，网络的构筑在当下一层的各个局部描述输出种误差最小值比上一层小或最后一层只有一个局部描述且其误差小于上一层的最小误差时停止，最后网络的输出根据这两种情况选取最后一个局部描述输出或前一层的各个局部描述输出的均值。本文将数据进行了划分，具体分为训练数据、选择数据及检验数据，用 MSE 控制节点的训练精度，用 BMSE (所有选择数据的输出均方差) 来选择好的局部描述，当然也可以选用其他规则来选择优化单元，如 AIC (Akaike 信息规则)。具体学习步骤如下：

第一步：数据预处理 将所有数据进行划分，划分为训练数据、选择数据和检验数据，并把所有数据归一到 $[0,1]$ 的范围内，为进行网络训练做准备。

第二步：创建一个初始的 GMDH 网络 隐层节点描述采用 RBF 网络，每个节点有两个输入，每个节点输出逼近期望输出，网络参数进行初始化。

第三步：用训练数据训练网络 将训练数据输入网络，训练网络各个 PE (处理单元)，直到各个 PE 输出满足给定精度要求时本层网络训练结束。

第四步：输入选择数据选择优化处理单元 将选择数据输入训练好的网络，计算所有 PE 的 BMSE，按照给定的阈值，选择那些 PE 的输出进入下一层网络。

第五步：判断网络层数递增截止与否 如果本层的最小 BMSE 大于上一层的最小 BMSE，那么停止网络训练进程，选择前一层作为输出层，网络最后输出为输出层各 PE 输出的均值。如果本层只有一个节点且其 BMSE 小于前一层的最小 BMSE，那么停止网络训练进程，本层作为输出层，其输出为网络最后输出。其他情况去第六步。

第六步：创建一新层网络 建一个新层 N-Adline 网络，初始化网络参数，已训练好的网络保留，去第三步。

第七步：检验网络性能 用评价数据 (可以包括训练数据和选择数据) 来检验网络拟合和泛化能力，也可用新的数据检验网络的大范围泛化能力。

3. 应用实例

第一个应用实例是对一可用式 (14) 表示的非线性系统进行辨识, 其输入输出模型可表示为:

$$y(k) = \frac{y(k-1)}{1+y^2(k-1)} + u^3(k-1) \quad (14)$$

其中 $u(k)$ 是在 $[-2.0, 2.0]$ 上的随机数, 输出变量 $y(k)$ 初始状态 $y(0) = 0$, 由式 (14) 生成了 120 组数据, 选取 4 个输入, 即 $u(k-1), u(k-2), y(k-1), y(k-2)$, 输出为 $y(k)$ 。本文采用交叉验证技术 (CV), 把生成的 120 组数据进行划分, 取 48 组作为训练样本, 另取 48 组作为选择样本用于中间变量的生成, 最后剩下的 24 组取作检验样本, 用于检验网络的大范围内的泛化能力。

(1) 运用 GMDH 网络辨识

首先采用传统的 GMDH 网络对该非线性系统进行辨识, 局部描述采用二次多项式函数, 学习规则基于 Widrow-Hoff 规则, 模型选择准则为正规准则 AR 准则, 训练后的网络结构如图 2 所示





图 2 系统的 GMDH 模型结构图

GMDH 模型经过动态构造网络, 逐层训练, 可以较好的拟合此非线性系统, 最后获得的拟合及泛化情况如图 3 所示



(— 实际值; —• GMDH 网络输出值)

图 3 GMDH 网络拟合所有样本结果图

(2) 运用本文的神经模糊 GMDH 网络进行辨识

网络局部描述采用前文提到的 RBF 网络和 Adline 网络 (非线性处理单元), 模糊 (RBF) 部分

采用梯度下降法 LMS 规则进行学习, 多层 Adline 网络部分学习采用 Widrow-Hoff 规则, 中间变量选择准则采用正规准则 (AR) 准则, 训练后的网络结构图如图 4 所示





图 4 系统的神经模糊 GMDH 模型结构图

运用上面的 NFGMDH 网络模型对该非线性系统获得的仿真结果如图 5 所示。

图中 120 组数据训练数据 48 组, 选择数据 48 组, 检验数据 24 组。从 NFGMDH 网络辨识后的结构可以看出, NFGMDH 网络可以去掉与输出关系不太紧密的输入, 如输入 $y(k-2)$ 对于网络的最后输出没有做任何贡献, 可以去掉。从最后的拟合情况来看, NFGMDH 网络无论在选择数据样本还是在检验数据样本拟合的结果都很好, 而且拟合情况比 GMDH 网络要好很多, 它具有更好的泛化能力 (选择数据拟合) 和大范围内超泛化能力 (检验部分拟合)。

(3) GMDH 网络与 NFGMDH 网络拟合结果比较



(— 实际值; —• NFGMDH 网络输出值)

图 5 NFGMDH 网络拟合所有样本结果图

通过比较图 3 和图 5 的拟合情况可以看出, 本文提出的 NFGMDH 网络比传统的 GMDH 网络拟合效果要好。为了说明这一点, 本文以实际拟合误差数据说明本文提出的 NFGMDH 网络具有较小的拟合误差, 见表 1

表 1 GMDH 与 NFGMDH 的拟合误差 (MSE) 比较表

	训练	选择	检验	总体
GMDH	1.8300	1.8043	3.8309	2.2199
NF-GMDH	0.5811	0.7758	1.2350	0.7898

第二个应用实例是运用 NF-GMDH 网络对乙烯工业中乙烯精馏塔的塔釜乙烯浓度进行估计。由于釜液中乙烯浓度受其他因素影响较多,如受塔釜压力、釜温、灵敏板温度、加热量及重组分波动变化影响,由工艺机理可知,这是一个典型非线性系统,准确估计釜液中乙烯浓度,对于减少乙烯损失,节省加热负荷具有重要的意义。本文以扬子石化烯烃厂乙烯精馏塔为例,选取塔釜压力、塔釜温度和灵敏板温度为输入变量,塔釜乙烯浓度人工分析值为输出变量,运用 NF-GMDH 网络对釜液中乙烯浓度进行了辨识,辨识结果如图 6 所示




图 6 NF-GMDH 辨识乙烯浓度结果图

图中 60 组数据中前 24 组为训练数据,接下来 24 组为选择数据,最后 12 组为检验数据,由图可以看出 NF-GMDH 网络有较好拟合能力,较强的泛化能力和大范围泛化能力,因此完全可以运用本文中的 NF-GMDH 网络来建立工业过程对象的软测量模型。

4. 结论

传统的 GMDH 由于局部描述采用多项式网络,拟合能力具有一定的局限性,本文提出一种模糊与 N-Adline 网络相结合的 NF-GMDH 网络,利用了 RBF 与模糊模型在一定条件下的等价性,利用 RBF 网络来进行模糊推理,实现了模糊与神经网络的完美结合,同时发挥了模糊模型良好的局部和全局拟合能力,结合局部描述采用 N-Adline 网络的 GMDH 较好的全局拟合能力,本文的 NF-GMDH 网络可以对非线性系统进行完美的拟合,这一点可以从本文

仿真实例中看出。因此, NF-GMDH 网络完全可以用于过程工业的软测量模型建模。目前,将模糊神经网络用于软测量模型建模的研究工作较少,希望本文能引起对应用模糊神经网络建立软测量模型研究工作的重视。

5. 参考文献

- [1] A.G.Ivakhnenko, Polynomial Theory of Complex Systems, IEEE Trans. On Systems, Man and Cybernetics, Vol.SMC-1, No.4, pp.364-378, 1971
- [2] Ohtani, T., Ichihashi, K. Nagasaka and T.Miyoshi (1997a). Successive Projection Method for Learning of Neurofuzzy GMDH, J. of Japan Society for Fuzzy Theory and Systems, Vol. 9,7, to appear, in Japanese.
- [3] Ohtani, T., Ichihashi, K. Nagasaka and T.Miyoshi (1997b). Function Approximation by Neurofuzzy GMDH with Error Backpropagation Learning J.of Japan Industrial Management Association, Vol.47, No.6, pp. 384-392, in Japanese.
- [4] M.Brown and C.Harris, Neurofuzzy Adaptive Modelling and control, Prentice Hall, New York, 1994.