

# 基于神经网络的非线性控制系统自组织辨识\*

胡德文 王正志 周宗潭

(国防科技大学自动控制系 长沙 410073)

**摘要** 本文首先将自组织神经网络算法向一般化情形引伸,接着把自组织过程应用到一般非线性系统的动态过程分类,使得整个非线性系统能够按照输入输出样本空间的概率密度自组织,成为许多具有不同分类核心和感受野的线性子空间逼近。在此基础上,我们采用通用最小二乘算法,以子空间的非线性问题线性化误差作为依据,并进一步运用自组织神经网络的合作与竞争思想,最终得到一般情形的非线性系统的最小二乘辨识。仿真结果表明了本方法的可行性与优越性。

**关键词** 非线性系统,神经网络,最小二乘算法,自组织算法,系统辨识

**分类号** TP271.62

## Self-organizing Identification of Nonlinear Control Systems Based on Neural Networks

Hu Dewen Wang Zhengzhi Zhou Zhongtan

(Department of Automatic Control, NUDT, Changsha, 410073)

**Abstract** This paper firstly extends the self-organizing neural networks to general case. Then the self-organizing process is applied to classify the dynamic process of nonlinear control systems. The nonlinear system is self-organized according to the probability density of the input and output samples and is approximated by many linear sub-spaces with different classifying centers and receptive fields. The self-organizing least squares identification of nonlinear systems is constructed based on the general least squares algorithms, the linearization errors of sub-spaces, and the cooperation and competition mechanism. The simulation results have shown the efficiency of the suggested algorithm.

**Key words** Nonlinear systems, neural networks, least squares algorithm, self-organizing, system identification

当前,非线性系统的辨识与控制,包括非线性自适应控制问题,仍是摆在控制界学者面前的难题。最小二乘本质上是对线性参数问题的估计算法,如要解决非线性问题只能通过物理分析或多因素实验等方法,确定出多个非线性项的数学表达式,而待估参数与输出观测值(或它的函数)仍呈线性关系。为解决非线性问题,已有许多新方法提出来,其中,神经网络方法就是极有前途的一种。

1989年, Martinez, Ritter, Schulten<sup>[1]</sup>采用 Kohonen<sup>[2]</sup>提出的自组织神经网络的思想,解决了机器人逆运动学问题。1990年,王正志、周宗潭<sup>[3]</sup>对 Martinez 等人的算法进行了改进,提高了收敛速度,在对机器人进行数千次的学习后,其终端的抓取精度可达到总臂长的0.5%。1992年,王正志<sup>[4]</sup>把改进的 M. R. S. 算法映射到非线性动态系统的自适应控制中,解决了很广泛的非线性系统的自适应控制,与 Narendra 和 Parthasarathy<sup>[5,6]</sup>用多层前传网络及其 BP 算法解决的非线性系统例子相比,在学习时

\* 1998年2月18日收稿  
国家自然科学基金,湖南省自然科学基金资助  
第一作者:胡德文,男,1963年生,教授

间和控制精度等方面都有显著优势。1993年,胡德文、周宗潭、王正志<sup>[7]</sup>将这种方法成功地运用到机器人眼手系统的实际协调控制中。

本文也将运用自组织神经网络的思想,采用不同思路,将它与最小二乘估计算法结合,解决一般情形的非线性控制系统的辨识问题。通过对具体例子的仿真,进一步验证本文提出方法的正确性,为最小二乘算法应用到非线性问题提供一种新的思想方法。

## 1 Kohonen 网络原理

Kohonen 网络是芬兰学者 Kohonen 于 1982 年提出的一种无导师自组织神经网络,其生理学依据是人脑的视皮层感觉映射所存在的自组织现象<sup>[2,8]</sup>。这个网络由一个全互联的神经元阵列组成,每个神经元的输出都是网络中任意一个神经元的输入。每个神经元接收的外部输入都是一样的。网络有二种权重,一是对外部输入反应的权重,另一种是神经元间的连接强度,控制着网络神经元间的相互作用大小。

当外部模式出现在网络的输入层时,每个神经元都同时工作。网络采用 WTA (胜者全取) 的竞争学习机制,遴选出一个神经元。网络训练好后,当同样的模式出现时,某个神经元兴奋起来,从而完成网络对输入模式的分类。

Kohonen 网络主要用于模式识别领域,如“声控打字机”的构思就是基于这一概念。该网络的学习算法是基于  $\delta$  规则型的。

## 2 自组织最小二乘辨识

Kohonen 提出的自组织网络是一种平面型的拓扑结构,这里的运用将有所不同。视情况,网络可以是一维、二维、三维,甚至更高维数的。

设待辨识的非线性系统描述为:

$$y(t+1) = f[y(t), \dots, y(t-n), u(t), \dots, u(t-m)] \quad (1)$$

其中  $u(t)$  和  $y(t)$  分别是控制系统的输入输出信号。 $f[\cdot]$  是连续的单值函数。为简单起见,这里仅考虑单输入单输出系统的情形。

把系统的动态过程用下面的向量来表示:

$$\mathcal{Q}(t+1) = [y(t), \dots, y(t-n), u(t), \dots, u(t-m)]^T \quad (2)$$

这时 (1) 式可重新表达为

$$y(t+1) = f[\mathcal{Q}(t+1)] \quad (3)$$

对于输入输出有界系统,这一关系概括了整个非线性状态空间。因此,非线性现象是十分复杂的,要用一个函数或一个多层前传网络逼近整个空间的非线性映射是困难的。由于  $f[\cdot]$  函数的形式常常是未知的,因此,采用非线性回归之类的办法行不通。

为解决这个问题,我们首先采用自组织神经网络,将整个空间划分成许多区域,每个区域用一个线性函数逼近。对这每个区域赋予一个权重,即分类核心  $W_s$ ,首先对它采用自组织算法进行训练。对区域  $s$  用一个神经元  $s$  对它负责,从视皮层的角度来讲,有一个感受野  $F_s$  和凝视点  $W_s$ 。

当输入向量  $\mathcal{Q}(t+1)$  落在神经元  $s$  的感受野  $F_s$  中时,设其对应的神经元的一阶线性化输出表示为:

$$y(t+1) = Y_s + A_s \mathcal{Q}(t+1) \quad (4)$$

这里的表达式与 Martinez 等<sup>[1]</sup>的一阶 Taylor 展开式不同,没有把分类核心  $W_s$  显式地体现在表达式中。为了求出线性函数的未知参数, Martinez 等<sup>[1]</sup>在文献中采用了两次测量策略。目的是要在两次测量(粗测量和精测量)的情况下,一次性求出二个系数。如果这二个系数都是标量,则这种方法无疑正确。如果这二个是向量和矩阵,问题就复杂化了,实际上是要求解不定方程组。如对一个三关节两摄像机的机械手眼手协调系统,要用 4 个方程求解出  $3 \times 4$  维的矩阵。为解决这个问题,以前的文献采用了沿垂直空间投影算子保留原有信息的方法,当然,公式也就复杂多了。

我们为什么不从长远的累积效果而仅仅是当前两步的观测来考虑问题呢?最小二乘的思想就是求

解超定的, 甚至是矛盾的方程组, 把落在神经元  $s$  感受野  $F_s$  中的外部模式  $\varphi(t+1)$  所对应的线性方程归并到一起, 采用最小二乘估计, 得到  $Y_s$  和  $A_s$  的值。逐个神经元地进行估计, 就辨识出了整个的非线性系统。

神经元  $s$  的选取如下式:

$$F_s = [\varphi \quad U \quad \varphi - W_s \leq \varphi - W_r, \forall r] \quad (5)$$

其中  $\varphi$  是外部输入, 即系统状态向量,  $U$  是其样本空间,  $W_r$  是神经元  $r$  的外部输入权重, 亦即分类核心; 神经元  $r$  是在  $n$  维整数空间中排列的,  $s$  是被选神经元;  $F_s$  是神经元  $s$  对应的输入子空间, 即神经元  $s$  的感受野。只要输入  $\varphi$  落在  $F_s$  内, 即  $\varphi$  与  $W_s$  的距离  $\varphi - W_s$  最短, 那么, 神经元  $s$  就在竞争中获胜而被选。这样就完成了对复杂模式的分类过程。从而, 把整个输入空间  $U$  的非线性辨识分成了 (4) 式的许多线性子问题。

设当前的训练时序为  $t$ , 当  $t+1$  步到来时, 已测得的系统状态向量  $\varphi(t+1)$  落在  $F_s$  内。这时, 首先是分类核心, 即网络的权重的调整:

$$W_r(t+1) = W_r(t) + \epsilon(t) h_{rs}(t) [\varphi(t+1) - W_r(t)] \quad (6)$$

其中  $r \in N_s$ , 而  $N_s$  是神经元  $s$  的邻域,  $\epsilon(t)$  为学习速率,  $0 < \epsilon(t) < 1$ ,  $h_{rs}(t)$  为邻域作用函数, 取为距离  $r-s$  的递降函数。胡德文等<sup>[9]</sup>通过对 Kohonen 网络的自组织过程的定性和定量分析, 提出了训练可分为二个阶段的新概念, 即第一个阶段是自组织的网络空间拓扑关系的形成过程, 通过邻域作用函数  $h_{rs}$ , 神经元之间相互协作, 使得网络构成有序拓扑结构。当外部输入模式靠近时, 响应神经元  $s$  在空间位置上也是靠近的, 这符合原来生理学上的意义。网络的第二个阶段称为“后训练阶段”, 它是在空间有序拓扑结构形成后, 神经元之间感受野的自组织划分和分类核心按输入空间概率密度进行自组织, 形成对输入空间的合理划分 (按输入样本出现的概率密度划分) 和神经元核心的合理布局。在后训练阶段, 网络的有序拓扑结构是稳定的。

假设通过适当选取网络训练策略和邻域作用函数, 网络已进入后训练阶段。在这一阶段, 网络开始它的系统辨识过程, 时间从  $t_1$  开始, 把  $t > t_1$  后利用 (5) 式选取所有落入  $F_s$  的输入模式  $\varphi(t+1)$  归并到一起, 采用最小二乘法, 求取公式 (4) 中的  $Y_s$  和  $A_s$  参数向量和矩阵。为了提高系统的实时运算能力和减小计算机内存, 可采用递推最小二乘估计算法。

但是, 我们在研究过程中发现, 当网络划分得足够细时, 虽然整体辨识误差可以达到非常高的精度, 但训练时间也要相应地增加。如果对总的训练时间加以限制, 那么, 有的区域可能因训练样本的不足而造成很大的误差。对这一现象, 我们可以采取两种不同的处理方式, 第一是对此作合作的解释, 即认为是合理的。事实上, 既然某感受野接受的样本很少, 那么, 它对应的辨识精度低, 只占整体中的很小份额, 如果以误差的概率加权作为最终辨识精度的衡量标准, 这种现象也就是合理的了。不过, 很可惜的是, 我们最近对自组织过程的研究表明, 在后训练阶段, 当样本数充分大时, 落入各神经元感受野的样本数目也是均衡的。对此, 下面我们采用主动的处理方式。

这种新的处理方法是, 把自组织过程的邻域作用函数也引入到最小二乘估计中, 当输入模式  $\varphi(t+1)$  落在  $F_s$  中时, 除了该区域的最小二乘估计启用外, 其邻域  $N_s$  中的相应参数辨识也或多或少地共享这种递推修正。修正的大小依赖于神经元  $r$  和  $s$  的距离。我们定义一个新的邻域作用函数  $\lambda_{rs}(t)$  这也是  $r-s$  的递降函数, 且  $0 < \lambda_{rs}(t) < 1$ 。

我们从时间轴上  $t > t_1$  开始, 考虑各感受野  $F_s$  中的最小二乘问题。在时间  $t > t_1$ , 各组最小二乘估计都将同时工作, 只是在参数递推估计中的修正值不同, 我们采用加权的最小二乘算法来体现各组参数辨识中的神经元邻域合作。在  $t > t_1$  的某个时刻, 如果神经元  $s$  选中, 则各组参数按正常递推进行。而它们的  $N_s$  邻域神经的其它各种参数, 视其距离  $r-s$  的大小, 也适当予以修正, 其权重就取为  $\lambda_{rs}(t-t_1)$ 。

根据以上的理论分析, 我们得到的自组织最小二乘递推算法是:

$$\theta_r(t+1) = \theta_r(t) + K_r(t+1) [y(t+1) - \phi(t+1) \theta(t)] \quad (7)$$

其中

:

$$K_r(t+1) = \lambda_s(t-t_1)P_r(t)\Phi_{t+1}[\mu + \lambda_s(t-t_1)\Phi(t+1)P_r(t)\Phi_{t+1}]^{-1} \quad (8)$$

$$P_r(t+1) = [I - K_r(t+1)\Phi(t+1)]P_r(t)/\mu \quad (9)$$

上面的递推公式中,  $\mu$  是遗忘因子,  $0 < \mu \leq 1$ , 它的引入可以使得时间  $t_1$  的选择有较大的灵活性, 因此是重要的。在 (7)、(8)、(9) 式中,  $\theta(t)$  为  $\theta$  估计量, 它为 (4) 式参数估计组成的向量:

$$\theta = [y_r, A_r]^T \quad (10)$$

而数据向量  $\Phi(t+1)$  是状态向量  $\phi(t+1)$  的增广向量:

$$\Phi_{t+1} = [1, \bar{\phi}(t+1)]^T \quad (11)$$

以上研究的是自组织最小二乘辨识算法。还有一点要指出, 为了使系统辨识的过程逐渐收敛到稳定, 自组织过程的邻域作用函数应逐步锐化, 使各区域的结果具有甄别性, 可以把  $h_{rs}(t)$  和  $\lambda_s(t-t_1)$  取为  $r-s$  的高斯型函数, 其方差分别随时间  $t$  和  $t-t_1$  逐步趋于零, 即

$$h_{rs}(t) = \exp[-(r-s)^2/\sigma^2(t)] \quad (12)$$

$$\lambda_s(t-t_1) = \exp[-(r-s)^2/\sigma^2(t-t_1)] \quad (13)$$

$$\text{其中, } \sigma(t) = \sigma_0 \exp(-\sigma t) \quad (14)$$

在自组织过程中, 学习速率  $\epsilon(t)$  可取为:

$$\epsilon(t) = \epsilon_0(\epsilon_1/\epsilon_0)^{t/t_1} \quad (15)$$

其中  $0 < \epsilon_1 < \epsilon_0 < 1$ 。

在自组织最小二乘辨识过程中, 各神经元  $r$  所对应的参数向量  $\theta(t)$  矩阵方差  $P_r(t)$  的初始值可取为:

$$\theta(t_1) = 0, P_r(t_1) = \alpha^2 I, \alpha \text{ 充分大} \quad (16)$$

### 3 仿真结果与分析

为了验证上述理论的正确性, 我们对如下 3 个典型的非线性控制系统进行仿真。这 3 个系统曾由 Narendra 和 Parthasarathy<sup>[5,6]</sup>于 1990, 1991 年用来验证 BP 算法辨识的可行性。

例 1 考虑非线性系统:

$$y(t+1) = \frac{y(t)y(t-1)[2.5 + y(t)]}{1 + y^2(t) + y^2(t-1)} + u^3(t) \quad (17)$$

将训练输入  $u(t)$  取为  $[-1, 1]$  之间均匀分布的白噪声。自组织划分过程的时间取为  $t_1 = 5000$ , 从  $t = t_1 + 1$  至 10000, 进行自组织最小二乘辨识。

为了测试其辨识效果, 采用:

$$u(t) = \sin(2\pi t/25) + \sin(2\pi t/10) \quad (18)$$

作为输入信号同时激励原系统和由神经网络新方法所辨识出的系统, 图 1 是 200 个数据点即 4 个周期的比较曲线。从图 1 看到, 辨识输出 (实线) 与理想输出 (虚线) 这两条曲线已具有较高的重合度。

例 2 考虑非线性系统:

$$y(t+1) = 0.8y(t) + [u(t) - 0.8]u(t)[u(t) + 0.8] \quad (19)$$

自组织网络采用  $5 \times 5$  结构。自组织划分过程时间取为  $t_1 = 5000$ , 辨识输入信号为  $u(t) \in [-1, 1]$  的均匀分布白噪声, 在经过约 2000 次的递推辨识后, 自组织辨识即已具有相当的辨识精度。

采用正弦信号作为测试用输入:

$$u(t) = 0.5 \sin(2\pi t/50) \quad (20)$$

图 2 是其比较曲线。从图 2 中看到, 辨识输出 (实线) 与理想输出 (虚线) 这两条曲线之间几乎已看不出差别。

例 3 考虑非线性系统:

$$y(t+1) = \frac{y(t)}{1 + y^2(t)} + u^3(t) \quad (21)$$

自组织神经网络采用  $10 \times 10$  的结构。训练所用的输入信号同例 1、例 2, 采用与例 1 同样的测试

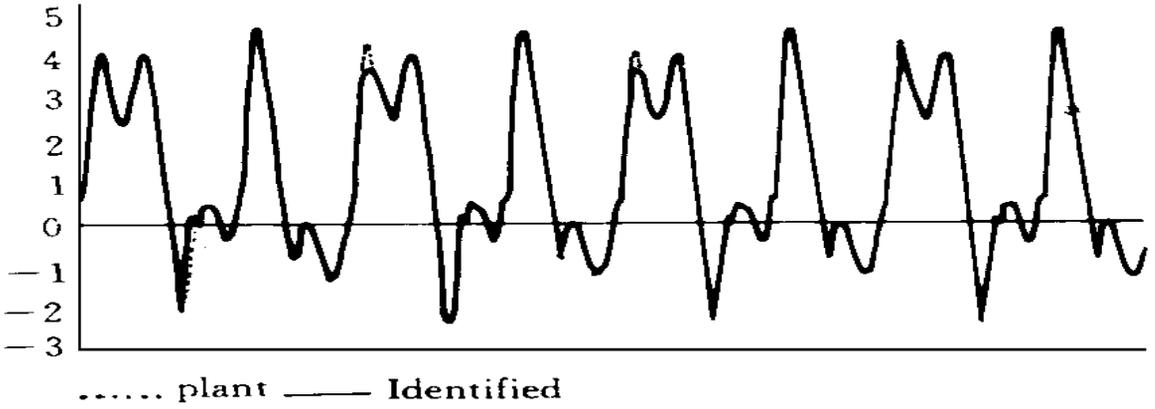


图1 例1 辨识效果比较曲线

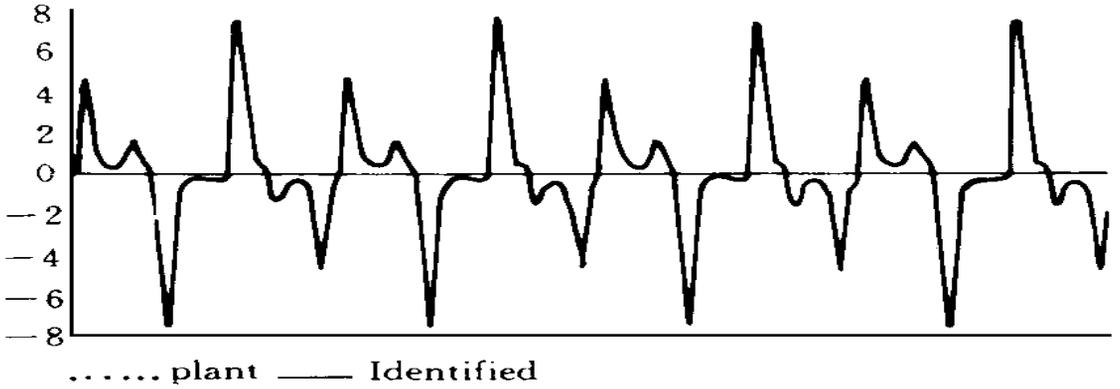


图2 例2 辨识效果比较曲线

信号 (18) 式作测试, 结果如图3 所示。辨识输出 (实线) 与理想输出 (虚线) 已具有很高的 consistency。

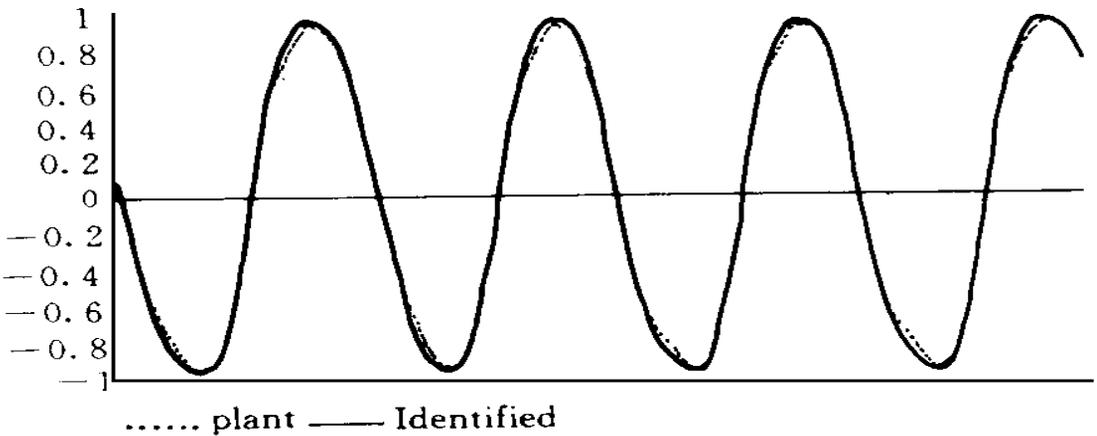


图3 例3 辨识效果比较曲线

以上3例的仿真在AST-386上进行, 用C语言编程, 为了便于直观比较, 例1和例2采用了较小的神经网络结构, 仿真表明, 通过扩大网络结构可达到任意满意的辨识效果。与Narendra和

Parthasarathy<sup>[5,6]</sup>的结果相比,本文方法所用时间仅为对应时间的1/5至1/10,而且在辨识精度上可得到更好的控制,可以避免BP算法所遇到的局部极小点问题。

## 4 结论

本文将自组织神经网络应用到一般非线性系统的动态过程分类,使得整个非线性系统按照输入输出样本空间,划分为许多具有不同分类核心和感受野的线性子空间。在此基础上,我们引入通用最小二乘算法,以子空间的非线性问题线性化误差作为依据,并进一步运用自组织神经网络的合作与竞争思想,最终得到一般情形的非线性系统的最小二乘辨识。

通过仿真表明,本文的方法是完全正确可行的,与采用BP算法为基础的多层前传网络等方法相比较,具有训练时间短、辨识精度高,以及可避免局部极小值问题等方面的优越性。可以很好地解决无噪声干扰下一般情形的非线性系统的辨识问题。这是本文的贡献所在。如何解决具有噪声干扰下非线性系统的辨识,是值得进一步研究的问题。

## 参考文献

- 1 Martinez T M. Ritter H J. Schulten K. J. Three-dimensional neural net for learning visuomotor of a robot arm. IEEE Trans. On Neural Networks, 1990, 1 (1): 131~136
- 2 Kohonen T. The self-organizing map. Proc. of IEEE, 1990, 78 (9): 1464~1481
- 3 王正志, 周宗潭. M.R.S. 自组织三维神经网络的改进及其在机器人控制中的应用. 自动化学报, 1992, 18 (1): 9~14
- 4 Wang Z Z. Hu D W. Self-organizing neural network adaptive control for nonlinear systems. Proc. Of the Intern. Joint Conf. On Neural Networks (IJCNN), Beijing, 1992, 3: 39~43
- 5 Narendra K. Parthasarathy K. Identification and control of dynamic systems using neural networks. IEEE Trans. On Neural Networks, 1990, 1 (1): 4~27
- 6 Narendra K. Parthasarathy K. Gradient methods for the optimization of dynamic system containing neural networks. IEEE Trans. On Neural Networks, 1991, 2 (2): 252~262
- 7 胡德文, 周宗潭, 王正志. 自组织神经网络的机器人眼手系统的研究: 一个实例. 首届全球华人智能控制与智能自动化大会论文集, 科学出版社, 1993
- 8 沈清、胡德文、时春主编, 神经网络应用技术, 长沙: 国防科技大学出版社, 1993
- 9 胡德文等. Kohonen 网络后训练阶段自组织的概率密度分布. 电子学报, 1995, 23 (8): 52~56