

# 具有动态补偿能力的神经网络模型及其在动态系统建模中的应用

张星昌

(中国科学院自动化研究所·北京, 100080)

**摘要:** 本文在多层前馈神经网络模型基础上, 引入误差动态反馈环节, 从而形成一种新的具有动态补偿能力的神经网络模型. 新模型的训练利用反向传播原理实现. 采用该模型对非线性动态系统进行建模时, 能显著提高建模精度, 特别是在网络模型工作时, 对新出现的输出误差具有动态补偿能力. 文中给出了新网络模型的结构和学习算法, 最后是仿真实例.

**关键词:** 多层前馈网络; 系统建模; 网络训练; 动态补偿

## 1 引言

多层前馈神经网络由于具有理论上能逼近任意非线性连续函数的能力, 且结构简单、易于编程, 因而在非线性系统建模和自适应控制中得到广泛应用<sup>[1,2]</sup>. 但是, 它存在两个缺陷: 第一, 实际非线性函数逼近能力有限<sup>[3]</sup>, 对某些非线性对象建模时, 存在较大的建模误差; 第二, 训练网络训练一旦完成, 权值就固定不变, 对模型工作时出现的动态误差无能为力. 为了提高多层前馈网络的非线性逼近能力, 需要增加网络的隐层节点数, 而这个数目常常是惊人的<sup>[3]</sup>, 使网络训练负担加重, 且带来“过拟合”问题<sup>[4]</sup>. 为克服动态误差, 需要对网络进行在线训练, 但还没有快速有效的在线学习算法.

为此, 希望能在不增加网络复杂性的情况下, 提高网络的非线性描述能力. 文献[5]提出一种输入补偿神经网络模型, 能有效消除网络的训练误差, 但该模型工作时易出现振荡, 且其动态补偿能力十分有限. 本文在补偿时采用一个动态环节实现, 使最终的动态补偿网络模型不仅有效降低训练误差, 而且模型工作时具有充分的动态补偿能力, 显著提高建模精度.

## 2 网络结构

动态补偿神经网络是在多层前馈网络基础上发展而成, 如图 1 所示为含一隐层的动态补偿神经网络结构(阈值未画出).

其中,  $n_I, n_H, n_O$  分别为输入层、隐层、输出层节点数,  $\mu = [\mu_1, \dots, \mu_{n_I}]^T, y = [y_1, \dots, y_{n_O}]^T, t = [t_1, \dots, t_{n_O}]^T$  分别为网络输入、输出及期望输出,  $\mu_{n_I+1}$  为补偿输入分量, 由网络训练(或工作)过程中实时提供. 图 1 中的动态环节具有如下特性:

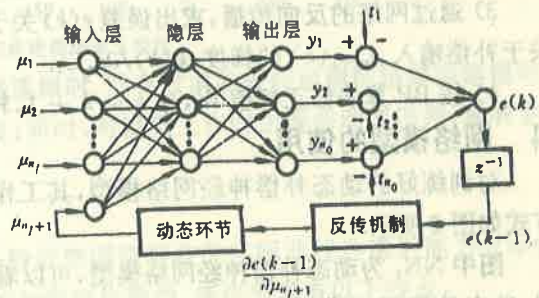


图 1 动态补偿神经网络结构

$$\mu_{n_j+1}(k) = \beta_0 \mu_{n_j+1}(k-1) - \beta_1 \frac{\partial e(k-1)}{\partial \mu_{n_j+1}} \quad (1)$$

这里  $\beta_0, \beta_1$  为适当选择的正常数,  $e(k)$  为网络的输出误差:

$$e(k) = \frac{1}{2} \sum_{j=1}^{n_0} (1/y_j(k) - t_j(k))^2 \quad (2)$$

### 3 网络的训练

虽然动态补偿神经网络包含包含动态环节,但其网络权的训练仍可近似采用静态网络的学习算法进行.训练可分两步进行,第一步,令  $\mu_{n_j+1}$  恒为 0,只训练多层前馈网络部分(记为  $NN_1$ )的连接权  $W$ ,可按一般的 BP 算法进行,得到最优值  $W_{opt}$ .第二步,在训练好的  $NN_1$  基础上,加入补偿输入节点和动态反传环节,进一步训练动态补偿网络(记为  $NN_2$ )的补偿权部分  $\bar{W}$ ,最终得到  $\bar{W}_{opt}$ ,与  $W_{opt}$  一起作为动态补偿网络模型的最最终权值.

给定非线性系统的输入、输出样本为  $\{(\mu(k), t(k)) | k = 1, \dots, n_p\}$ ,其中  $\mu(k), t(k)$  分别为  $n_i$  维、 $n_0$  维样本输入、输出向量,  $n_p$  为样本总数.则动态补偿神经网络  $NN_2$  按下列步骤训练:

第一步,以  $\{(\mu(k), t(k)) | k = 1, \dots, n_p\}$  为样本,按一般的 BP 算法训练前馈网络  $NN_1$ ,得权值为  $W_{opt}$ .

第二步,在训练好的网络  $NN_1$  基础上,加入动态补偿节点,进一步训练  $NN_2$  的补偿权  $\bar{W}$ ,具体过程如下:

1) 置初值.令权向量  $\bar{W}$  取  $-0.5 \sim 0.5$  的随机数为初值,并令  $\mu_{n_j+1}(0) = 0$ ,

$$\frac{\partial e(0)}{\partial \mu_{n_j+1}} = 0.$$

置  $k = 1$ ;

2) 计算  $k$  时刻的补偿输入分量  $\mu_{n_j+1}(k)$ :

$$\mu_{n_j+1}(k) = \beta_0 \mu_{n_j+1}(k-1) - \beta_1 \frac{\partial e(k-1)}{\partial \mu_{n_j+1}}.$$

然后与输入样本  $\mu(k) = (\mu_{k1}, \dots, \mu_{kn_i})^T$ ,共同作用于带动态补偿的网络  $NN_2$ ,经前向传播,得到网络的输出向量  $y(k) = (y_{k1}, \dots, y_{kn_0})^T$  及输出误差  $e(k)$ .

3) 通过网络的反向传播,求出误差  $e(k)$  关于补偿权  $\bar{W}$  的梯度向量  $\partial e(k)/\partial \bar{W}$ ,以及  $e(k)$  关于补偿输入  $\mu_{n_j+1}(k)$  的梯度  $\partial e(k)/\partial \mu_{n_j+1}$ .

4) 按 BP 算法修正权值  $\bar{W}$ ,令  $k = k + 1$ ,转 2)。

### 4 网络模型的使用

对训练好的动态补偿神经网络模型,其工作方式如图 2 所示.

图中  $NN_2$  为动态补偿神经网络模型,可以看到,动态补偿网络模型在工作时,能利用每步的模型误差,实现在线补偿,从而形成一个完善的闭环建模系统.




图 2 动态补偿网络模型的工作方式

### 5 仿真研究

建模对象选为文献[6]中 296 对气体炉输入输出数据. 建模目的就是寻求输出量和输入量之间的非线性动态映射关系. 我们分别用多层前馈网络模型及其相应的动态补偿网络模型进行对象的建模, 训练样本取前 120 对输入、输出数据, 其余数据用以对所建模型的检验. 结果如图 3、图 4 所示, 其中点线为系统输出的实际观测值, 实心线的前 120 步为网络模型的训练结果. 后面的 169 步为所建模型的预报结果.




图 3 多层前馈网络建模结果及预报




图 4 动态补偿网络建模结果及预报

仿真结果表明, 用动态补偿神经网络模型建模时, 能有效消除多层前馈网络模型建模时所不能进一步减小的固有误差, 提高建模精度; 同时, 对模型工作时出现的动态误差, 具有在线补偿能力, 效果显著.

### 6 评注及结语

本文针对用于非线性动态系统建模的一般前馈网络存在的实际非线性逼近能力有限、缺乏动态补偿能力的缺陷, 提出一种动态补偿神经网络模型. 新模型具有以下特点:

- 1) 动态补偿的引入, 形成了一个完善的闭环动态建模系统, 提供了模型的在线补偿能力.
- 2) 对补偿权  $\bar{W}$  训练是动态进行的, 因而有充分的激励, 使得训练后的  $\bar{W}$ , 对很大范围

内的输出误差都有抑制作用。

3) 对补偿权  $\bar{W}$  训练的同时,也对补偿输入进行动态调节,使最终的补偿达到最优,因而对误差的抑制作用也最强。

4) 补偿网络的训练是在多层前馈部分的权值  $W$  训练好的基础上,仅对补偿权  $\bar{W}$  部分进行,因而训练简单、易于实现。

动态补偿网络的提出,把误差反馈原理巧妙地引入到神经网络建模中来,使模型不仅具有学习功能,而且具有在线动态补偿功能;对模型的训练误差有很强的消除能力,同时对模型工作时出现的新误差也有相当的抑制作用,从而克服了采用一般的在线学习方法时难以避免的学时间过长、不能满足实时需要的困难。仿真试验证明了新模型的有效性。

### 参 考 文 献

- [1] Chen, S. and Billings, S. A. . Neural Networks for Non-Linear Dynamic System Modelling and Identification. *Int. J. Control*, 1992, 56(2): 319—346
- [2] Nordgren, Richard E. and Meekl. Peter H. . An Analytical Comparison of a Neural Network and a Model-Based Adaptive Controller. *IEEE Trans. on Neural Networks*, 1993, 4: 685—694
- [3] Hunt, K. J. , et al. . Neural Networks for Control Systems—A Survey. *Automatica*, 1992, 28: 1083—1112
- [4] Langonnet, Philippe. Process Control with Neural Networks; an example. *SPIE*, 1709 Applications of Artificial Neural Networks II, 1992: 468—475
- [5] 孙宝成. 神经网络理论研究及其在控制中的应用. 中科院自动化研究所博士论文, 1994, 62—105
- [6] Box, G. E. P and Jenkins, G. M. . Time Series Analysis Forecasting and Control. Holden-Day Inc, 1976

## A Neural Network Model with Dynamic Compensation and its Applications in Dynamic System Modelling

ZHANG Xingchang

(Institute of Automation Academia Sinica · Beijing, 100080, PRC)

**Abstract:** By introducing a dynamic error feedback link in a multi-layer feedforward neural network, this paper proposes a new neural network model which has the dynamically compensating capability. During both training and working of this new network model, we apply the principle of dynamic error back-propagation to make the feedback compensation. Using this model in nonlinear dynamic systems modelling, the dynamic error can be effectively reduced and the modelling accuracy can be significantly raised. The structure and learning algorithm of this new neural network model are given. The application to real data modelling is included to demonstrate the effectiveness of the new model.

**Key words:** multi-layer feedforward networks; system modelling; training of networks; dynamically compensating

### 本文作者简介

张星昌 1964年生, 1984年中山大学数学系毕业, 1992年北京理工大学自动控制系硕士毕业, 现为中科院自动化所博士研究生. 主要研究方向为动态系统建模和神经网络理论.