

人工神经元网络在系统辨识中的应用

徐耀玲 戴汝为
(中国科学院自动化研究所)

摘要

本文将人工神经元网络的非线性和信息的分布性用于非线性静态模型的辨识。对化工生产中的缩聚反应过程的辨识结果表明,用人工神经元网络来辨识非线性静态模型是可行的,从而为系统辨识提供了一条新的途径。

关键词: 神经元网络, 反向传播, 辨识。

一、人工神经元网络原理

近年来,人工神经元网络(以下简称神经元网络)的研究受到了人们的极大关注,至今已提出了若干种模型,并获得了广泛的应用。但在控制领域的应用国内目前尚不多见。

神经元网络是由大量的被称为节点的简单信息处理元件组成的^[1-2],每个节点向邻近的其它节点发出抑制或激励信号,整个网络的信息处理便是通过所有这些节点相互作用完成的。研究者们希望用这样一个网络来模拟人脑神经元组织的信息处理机制。通常在节点处进行的运算是非线性的,由它们组成的网络便也呈现非线性。此外,网络还具有信息的分布性,与以往的人工智能中基于冯·诺依曼机制的显式、独立的信息存贮方式不同,神经元网络信息存贮是隐蔽地分布在整個网络中,每一节点及各节点间连线上的权值与存贮的整个信息都相关。这种分布式存贮方式本身就已对信息进行了加工。

神经元网络的一个主要模型是反向传播(Back-Propagation)模型(以下简称BP模型)^[1-3],其结构如图1所示。

网络运行时输入模式首先通过加权传到隐节点,经过作用函数的作用再送到输出节点。作用函数 f 须是可微、非减

的,通常取为 S型函数 $f(x) = \frac{1}{1 + e^{-x}}$.

网络通过反向传播算法自动学习内部表达(即各节点间连线的权值及隐节点与输出节点的阈值),整个过程为:首先根据当前的内部表达,对样本输入模式作前向计算,然后比较网络的输出与期望输出,若误差小于规定值,则学习结束,否

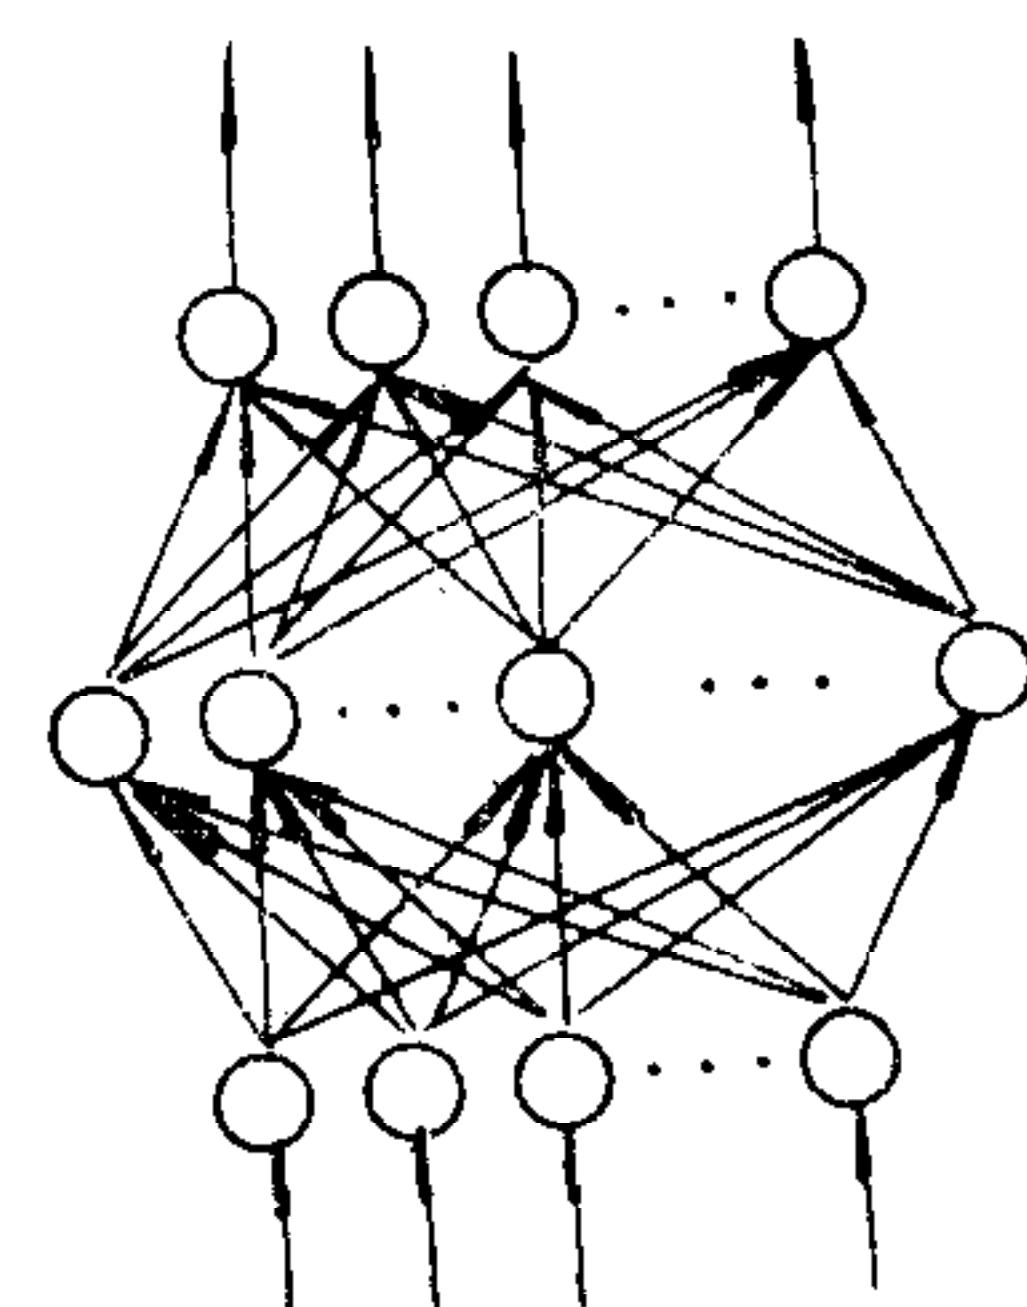


图 1 BP 模型

则将误差向后传播,逐步调整权值、阈值。如此循环,直至误差达到要求。

对于具有 n 个输入节点, m 个输出节点的 BP 网络, 输入到输出的关系可看作是一 n 维欧氏空间到 m 维欧氏空间的映射 $F: \mathbf{y} = F(\mathbf{x})$, 其中 \mathbf{x}, \mathbf{y} 分别为输入、输出向量。由于网络中含有大量非线性节点, 所以 F 具有高度非线性。

对于一组学习样本 $\{\mathbf{x}_i, \mathbf{y}_i\}$ ($i = 1, 2, \dots, k$), 可认为存在一映射 G , 使得 $\mathbf{y}_i = G(\mathbf{x}_i)$ 。网络对此样本集学习, 实际上就是自动寻找一种内部表达, 它实现映射 F , 使得在某种指标下, F 足够逼近 G 。对 BP 网络, 只要有足够多的隐节点, 网络能实现任意输入到输出的映射。

上述性质使 BP 网络在静态模型辨识中的应用成为可能。将控制对象看作一黑箱, 以实测输入输出数据为样本, 送入 BP 网络中学习, 确定其内部表达, 使其输入到输出的映射与对象的相逼近, 整个网络模拟出系统的外部静态特性。

由于 BP 网络的信息分布性, 各输入变量对输出变量的影响在对样本进行学习时就已自动记下并由整个网络的内部表达而表现出来, 从而省去了通常建模前所需的对各变量的相关性分析。又由于 BP 网络自身的非线性, 用它来逼近非线性系统就显得更自然。另外, 神经元网络可连续学习, 当模型不再满足要求时, 可在原基础上, 通过提高学习精度或增加新的样本, 继续学习, 使模型和对象进一步逼近。

二、辨识实例

图 2 是天津石化总公司涤纶厂的间歇式缩聚反应示意图。反应完成与否是根据反应釜中物料是否达到要求的特性粘度值来判断的。目前, 国内外大部分缩聚反应器没有直接测量粘度的仪表, 而是根据搅拌电机的功率来间接推断粘度值。在理想情况下, 即环境(电压、电流、电网频率等)、工艺参数(投料量、温度、转数等)稳定时, 搅拌功率和粘度值有固定的对应关系。但实际环境和工艺参数往往会有变化, 这就给根据功率推断粘度带来了困难和误差。目前工厂是根据经验对功率进行修正, 当功率达到修正值后, 就可以出料。经验公式如下:

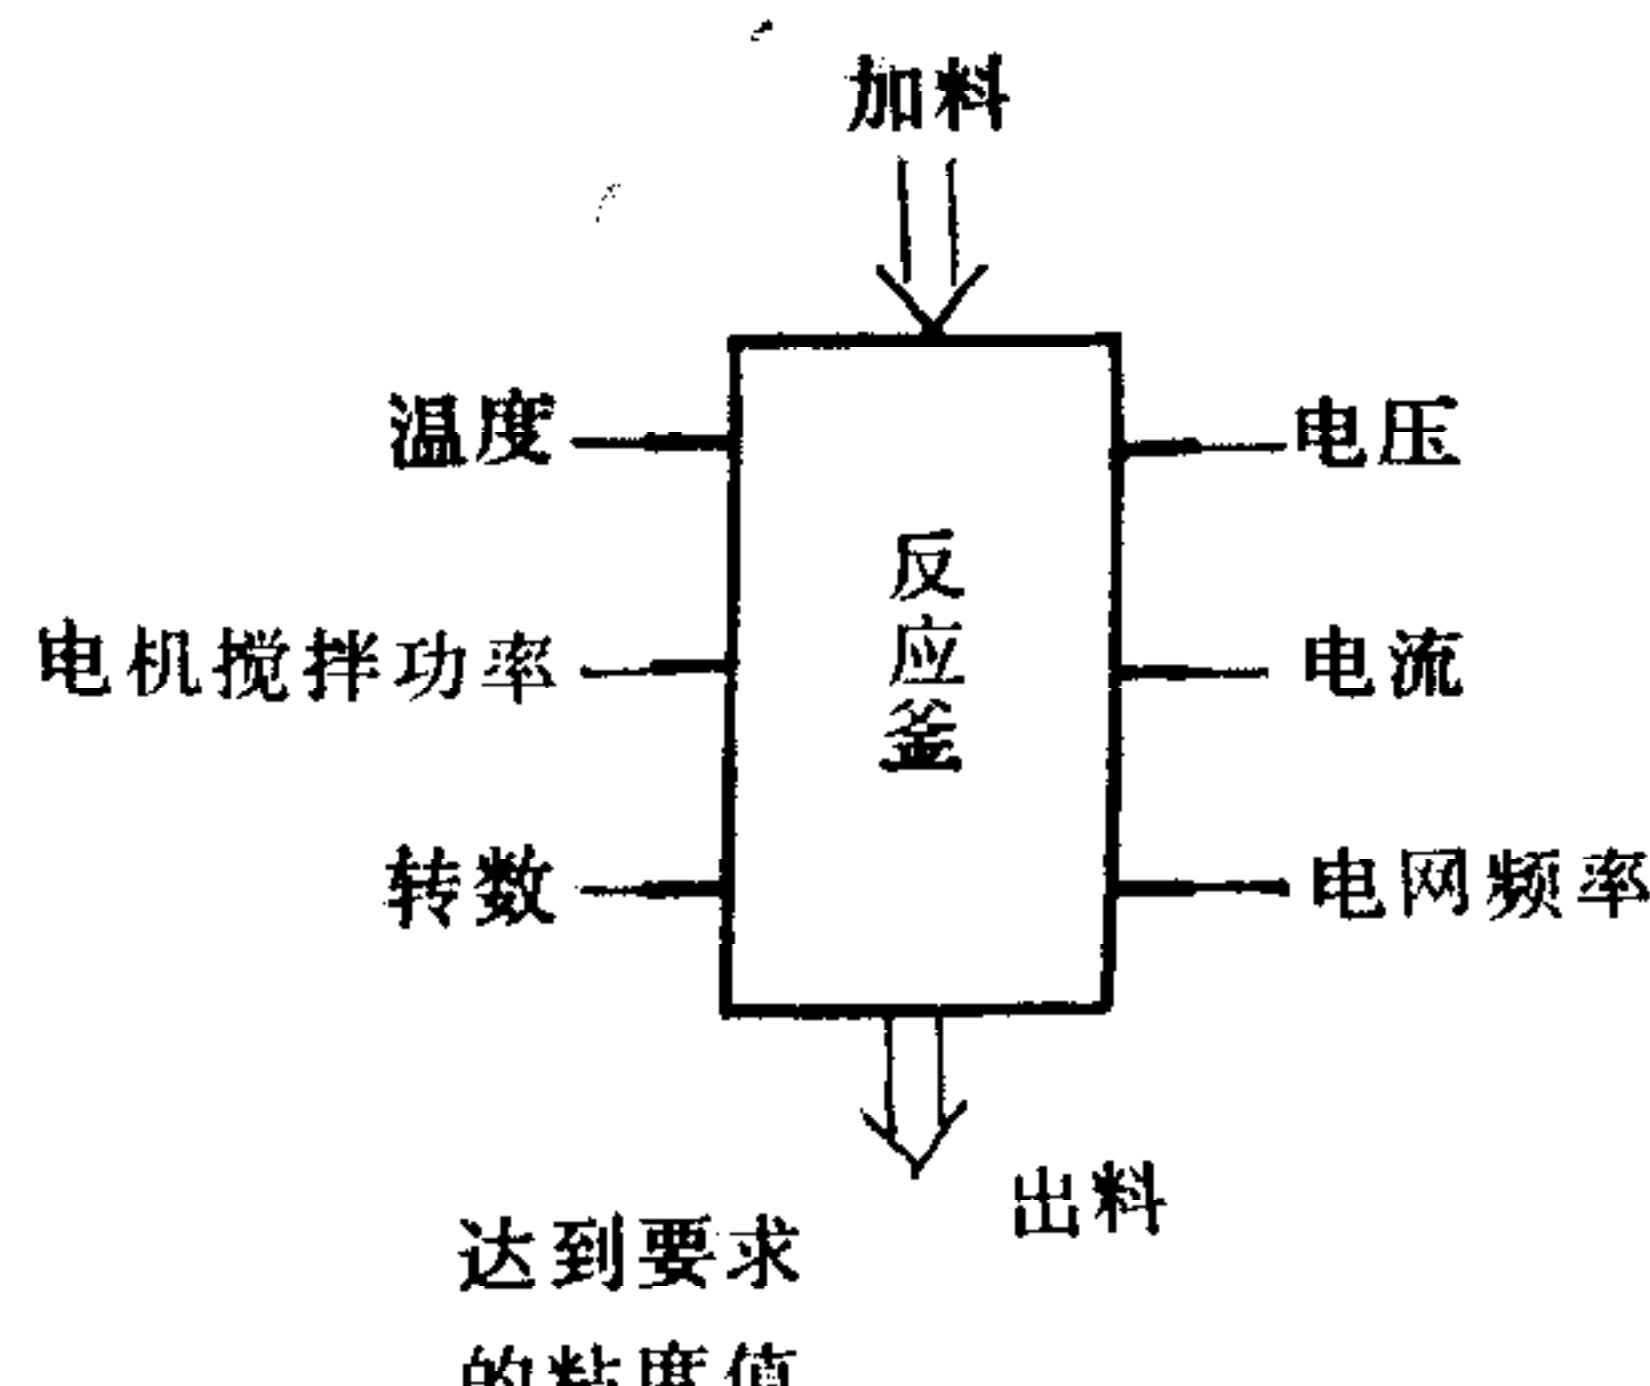


图 2 反应示意图

1) 物料补正: $\pm 30\text{kg}$ 修正: $\pm 0.1\text{kW}$
 2) 温度补正: $\pm 1^\circ\text{C}$ $\mp 0.1\text{kW}$

- 3) 粘度补正: ± 0.002 $\pm 0.1\text{kW}$
 4) 电压补正: $\pm 10\text{V}$ $\pm 0.4\text{kW}$

由图 3 可知, 这种线性比例补正误差较大, 根据它计算出的结果与实际功率比较, 最大偏差高达 1119.4W , 均方差为 488.9W (实际功率值变化范围为 $12500\text{--}16900\text{ W}$)。本文根据从现场采集的 49 组数据, 用 BP 网络来建立此对象的数学模型, 即寻找电机转数 n 、电网频率 f 、电压 V 、投料量 Q 、电流 I 、温度 T 、粘度 IV 与电机搅拌功率 W 的关系

$$W = q(n, f, V, Q, I, T, IV).$$

构造一个三层 BP 网络, 输入节点、隐节点、输出节点数分别为 7, 5, 1。选择 24 组较有代表性的实测数据作为网络的学习样本(考虑到对模型的检验, 只用了一半数据作为学习样本), 送入网络中学习, 得到模型 $P24mod$ 。其学习精度为 129W, 即模型输出与学习样本输出误差小于 129W。

将 49 组数据全部送入 $P24mod$ 检验, 可知模型的输出与实际测量值拟合程度较好。25 组非学习样本中大多数也能满足模型的误差要求。模型的外延性较好, 仅个别点偏差较大。模型最大偏差为 434W, 均方差为 127.2W, 误差远比经验规则的小。模型与实测数据、经验规则与实测数据的比较分别见图 3 和图 4。

此外, 就目前情况看, 在精度上, $P24mod$ 已接近以往的系统辨识中用多项式逼近对

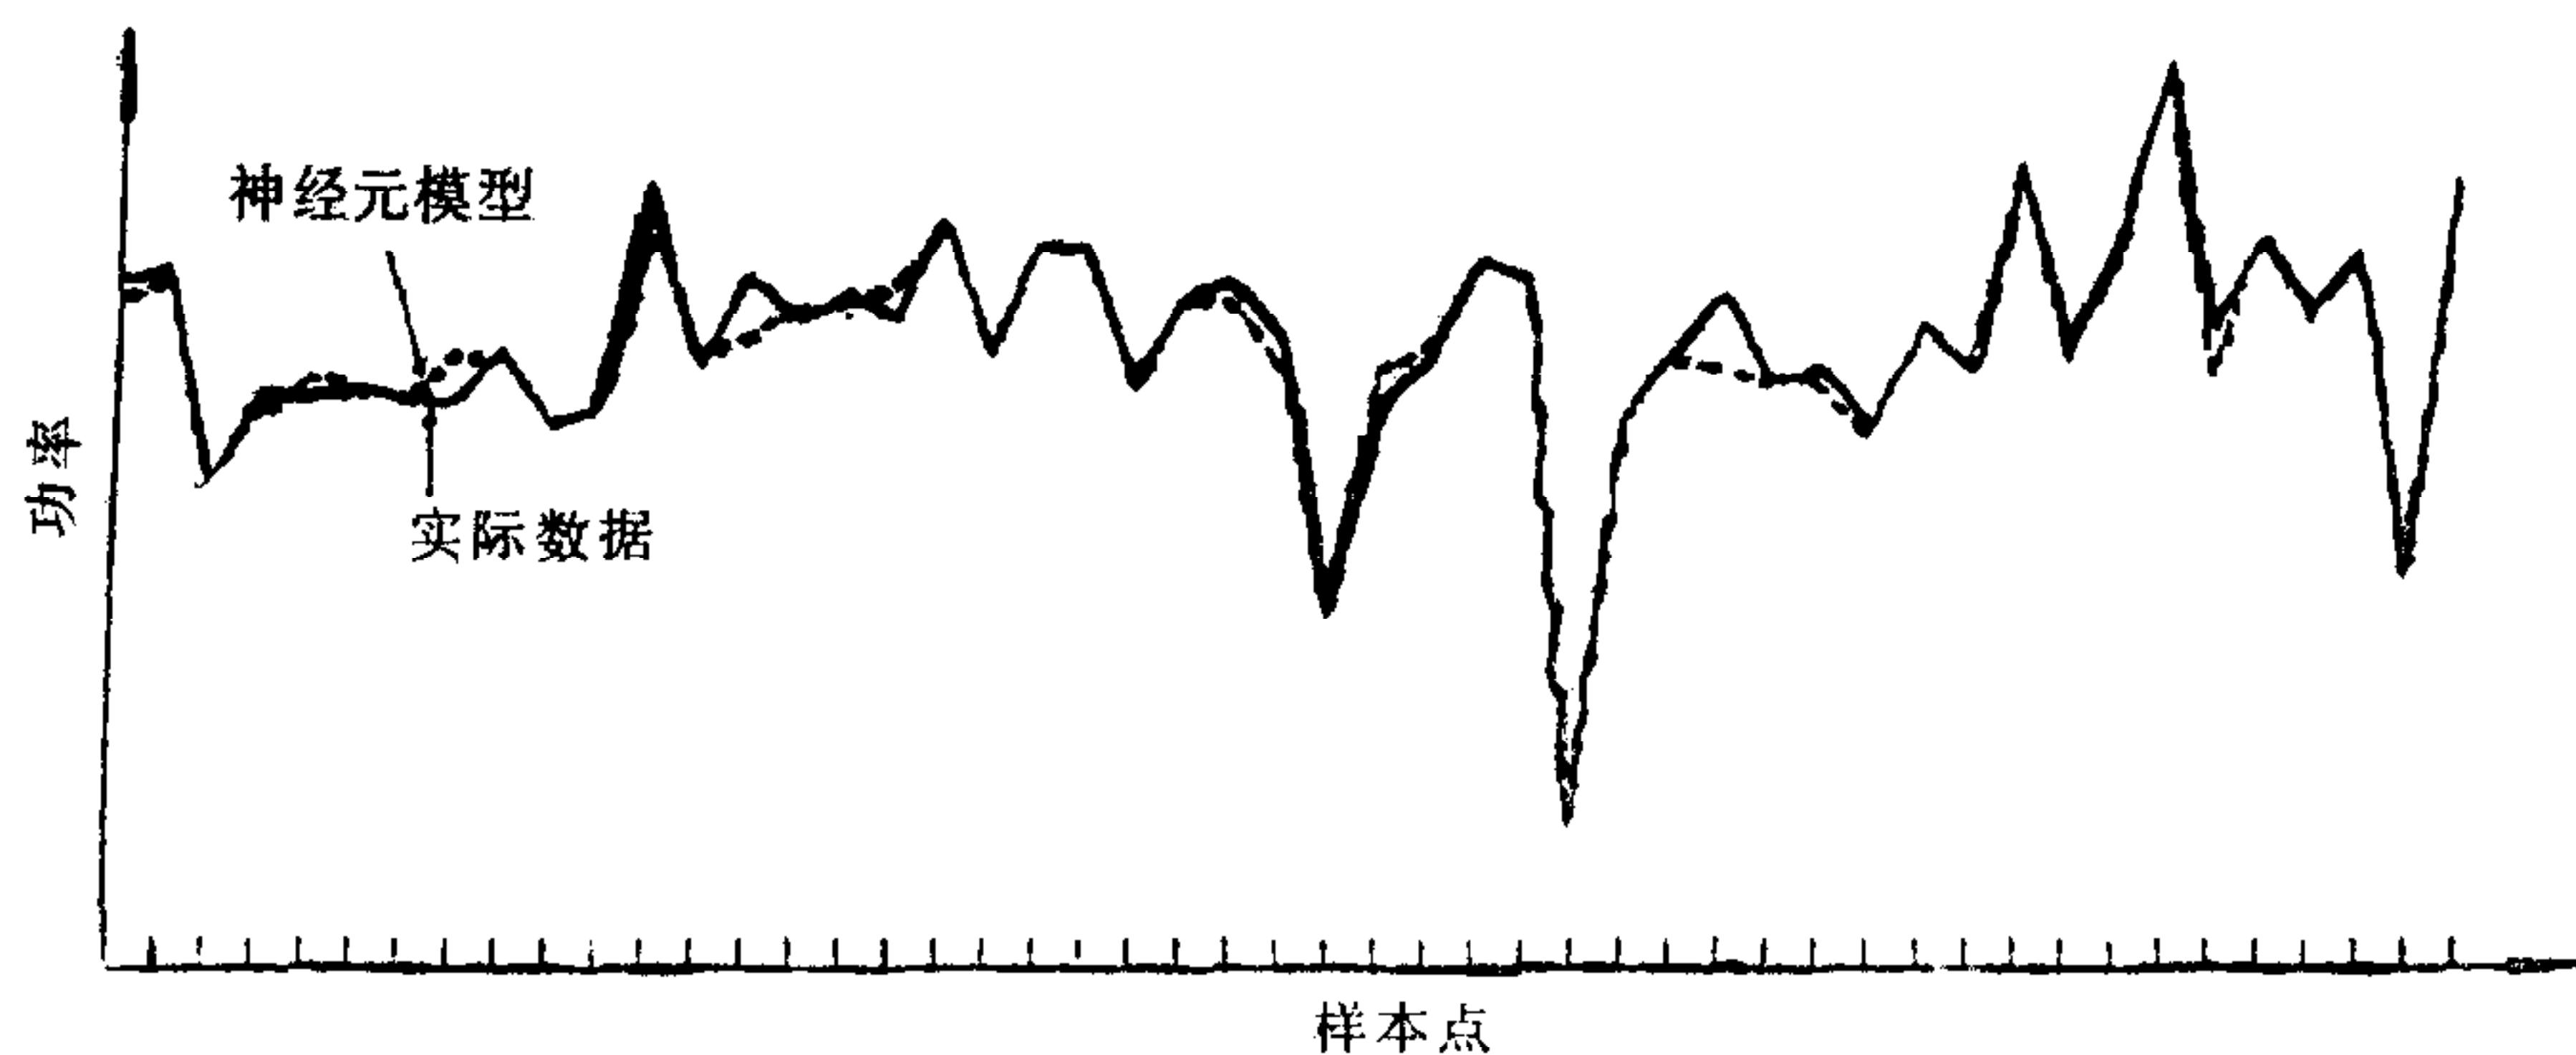


图 3 神经元网络模型的输出与实测值的比较

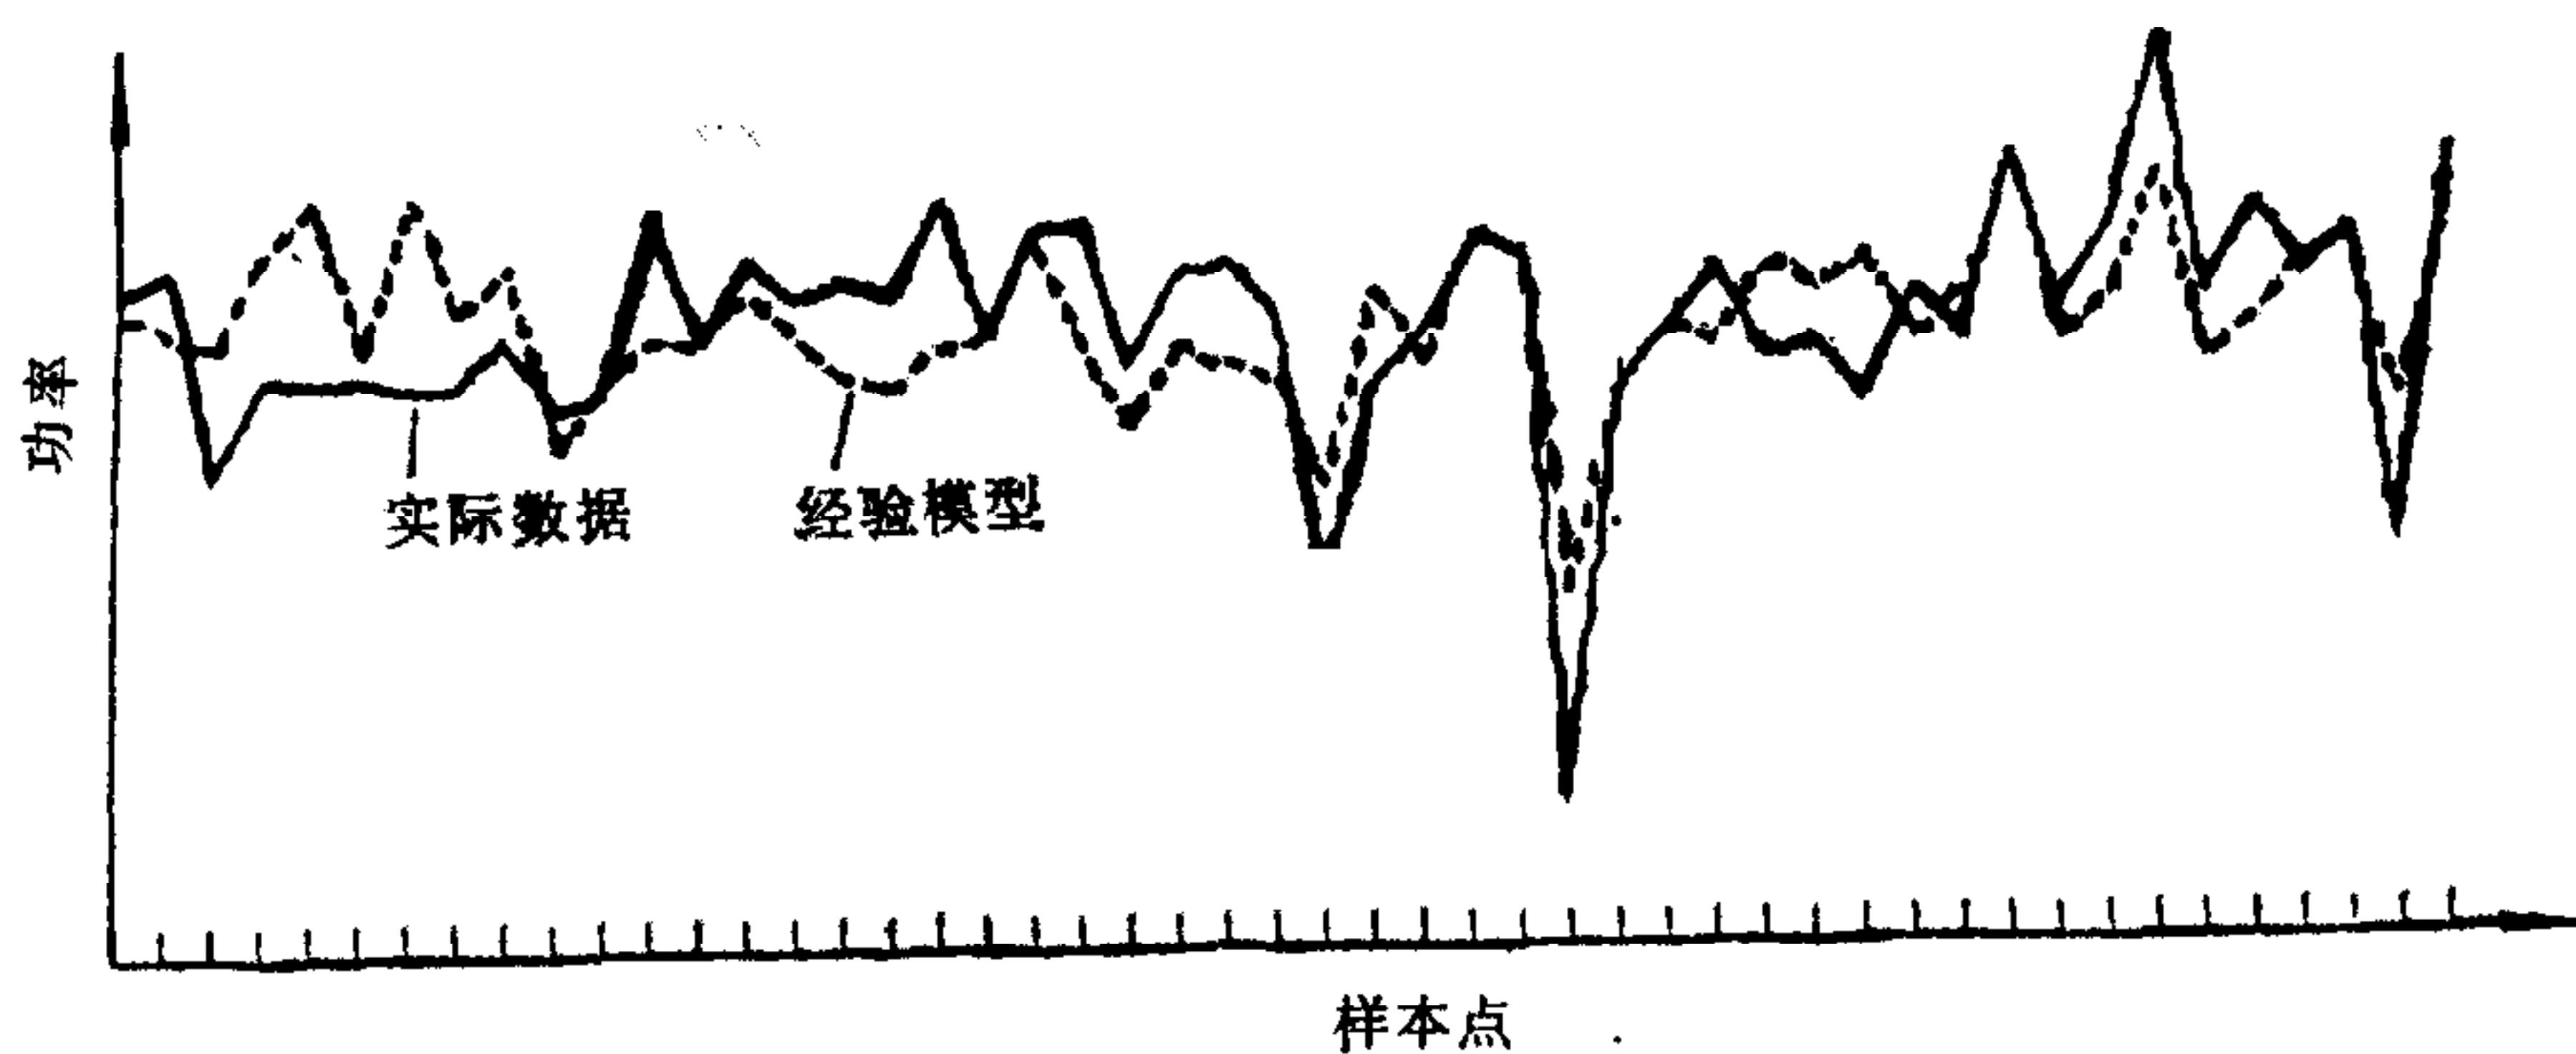


图 4 经验模型的输出与实测值的比较

象, 根据最小二乘法作参数辨识, 对 40 个样本所建的模型, 后者的最大偏差为 212W, 均方差为 87W。

本文作者在研究中, 得到中国科学院自动化所的高东杰, 王珏同志的帮助, 谨此致谢。

参 考 文 献

- [1] 尹红风, 戴汝为, 人工神经元网络信息处理原理, 模式识别与人工智能, (1990), 第一期.
- [2] Rumelhart, D.E. et al., Learning Internal Representations by Error Propagation, in Parallel

Distributed Processing in the Microstructure of Cognition, MIT press, 1986.
[3] William, P. Jones and Josiah Hoskins, Back-Propagation, Byte, 1987.

An APPLICATION OF ARTIFICIAL NEURAL NETWORK TO SYSTEM IDENTIFICATION

XU YAOLING DAI RUWEI

(Institute of Automation. Academia Sinica)

ABSTRACT

The nonlinearity and distribution of information processing of the artificial neural network are utilized in the identification of nonlinear static model. The identification of condensation polymerization process in the chemical industry shows that it can be practicable to adopt artificial neural network to identify nonlinear static models. Therefore, a new way of system identification may be feasible.

Key words: Neural network; back-propagation; identification.