

链式数据重组与神经网络在经济预测中的应用

邱跃茹¹, 朱维彰², 诸 静¹

(1. 浙江大学 电气工程学院, 浙江 杭州 310027; 2. 杭州电子工业学院 自动化系, 浙江 杭州 310037)

摘要: 建立经济模型和基于模型对宏观经济进行预测, 是经济运行质量评价、仿真、制定发展规划等所必不可少的. 针对宏观经济预测的特殊性: 样本少、时变性, 提出了反向传播(BP)神经网络的链式数据重组训练方法, 并用于实际经济预测. 和原数据用于预测的结果相比, 达到了较高的预测精度. 同时, 解决了 BP 神经网络难以确定隐结点数的问题.

关键词: 宏观经济预测; 数据重组; 神经网络训练

中图分类号: TP18 **文献标识码:** A

Application of the chain style data recombination method and neural networks in macroeconomic forecast

ZHI Yue-ru¹, ZHU Wei-zhang², ZHU Jing¹

(1. College of Electrical Engineering, Zhejiang University, Hangzhou Zhejiang 310027, China;

2. College of Automation, Hangzhou Institute of Electronic Engineering, Zhejiang Hangzhou 310037, China)

Abstract: It is necessary to model predict and model the economic system and for evaluating economic circulation, simulation, and making development programs. Based on the characteristics of the macroeconomic forecast, such as small data sets and time-varying, a chain-style data recombination method is presented, which is used for the back-propagation (BP) neural networks training. This method was applied to real macroeconomic forecast, and achieved the higher forecasting precision than the original data sets. It also solves the problem how to decide the hidden node numbers for the BP neural networks.

Key words: macroeconomic forecast; data recombination; neural networks training

1 引言(Introduction)

宏观经济系统涉及很多因素, 机理很复杂. 有人认为经济模型是一种接近黑箱的模型^[1]. BP 神经网络^[2]具有很强的构造输入空间与输出空间非线性映射的能力, 可以期望 BP 神经网络在解决宏观经济建模和预测问题上会有良好的应用前景. 但由于经济问题自身的特征, 在应用 BP 网络时, 需要注意三个问题的解决.

1) 可用于训练的样本数少. 经济的主要统计量往往以年为周期. 中国大陆能用于建模和预测的样本数据仅仅只有 20 多年. 由于样本数据少, 只能采用规模小的 BP 网络, 而且容易造成过拟合^[3].

2) 时变性. 经济系统有明显的时变性. 显然, 由于存在时变性, 不能平等地对待每一个训练样本, 应该是越接近当今年份的样本. 在训练中越起重要作用.

3) 难以确定隐结点数. 隐结点数 q 是 BP 网络反映结构的参量, 目前尚无选择合理的 q 值理论. 但是可以定性地肯定, 由于样本数少, q 只能在小正整数中选择.

针对上述 3 个问题, 作者提出了链式样本重组的前馈神经网络训练方法, 并将其用于某大城市 GDP 的预测. 结果表明, 本文中的方法是有效的.

2 链式数据重组训练方法(Chain style data recombination training method)

除保留时间最近的一组样本作为检验用外, 设可以用于训练的样本为

$$P_j \triangleq (y_{k-j+l}, X_{k-j}), j = 0, 1, \dots, N-1. \quad (1)$$

其中, N 为样本数, X_{k-j} 为网络输入向量, y_{k-j+l} 为网络期望输出, $l \geq 0$ 为预测步长.

链式数据重组方法包括三部分:

1) 选择均方误差调整函数 $\{V_j, j = 0, 1, \dots, N - 1\}$, V_j 为整数, 并且

$$V_0 \geq V_1 \geq V_2 \geq \dots \geq V_{N-1} = 1. \quad (2)$$

2) 链式样本重组.

将原始样本 $P_j (j = 0, 1, \dots, N - 1)$ 先作如下排列:

$$V_{N-1} \uparrow \begin{cases} P_{N-1} \\ \vdots \\ P_{N-1} \end{cases}, V_{N-2} \uparrow \begin{cases} P_{N-2} \\ \vdots \\ P_{N-2} \end{cases}, V_{N-3} \uparrow \begin{cases} P_{N-3} \\ \vdots \\ P_{N-3} \end{cases}, \dots, V_0 \uparrow \begin{cases} P_0 \\ \vdots \\ P_0 \end{cases} \quad (3)$$

再从左至右, 逐行进行链接. 第 i 行最右的样本链接第 $i + 1$ 行最左面样本 ($i = 1, 2, \dots$) 构造出新的样本序列, 称为链式样本序列. 由式(3)易知, 链式样本序列长度为

$$N_s = V_0 + V_1 + \dots + V_{N-1} \geq N. \quad (4)$$

事先给定隐结点数 q 及小正实数 a , 然后按传统的 BP 网络训练方法(如 Levenberg - Marquardt 方法), 以链式样本与网络实际输出误差平方和最小为训练指标. 每输入一个链式样本, 修正一次权向量, 训练周期为 N_s . 由式(3)可知, 原始样本 P_j 在一个训练周期内重复出现 V_j 次, 但由于采用逐样本修正权向量的方法, 在同一个周期内, 原始样本前后重复出现时, 其权向量并不相同, 因而修正效果也不一样. 从这个意义上讲, 原始样本集数被扩充为 N_s .

当权向量趋于常向量 w 时, 记链式样本与网络实际输出误差为

$$\epsilon_j \triangleq y_{k+l-j} - f(q, w, X_{k-j}).$$

如果对应于链式样本的误差平方和

$$J \triangleq \{\epsilon_{N-1}^2 + \epsilon_{N-2}^2 + \dots + \epsilon_0^2\} + \{\epsilon_{N-2}^2 + \epsilon_{N-3}^2 + \dots + \epsilon_0^2\} + \dots + \{\epsilon_{N-3}^2 + \epsilon_{N-4}^2 + \dots + \epsilon_0^2\} + \dots + \{\epsilon_{N-3}^2 + \epsilon_{N-4}^2 + \dots + \epsilon_0^2\} + \dots + \{\epsilon_0^2\} + \{\epsilon_0^2\} + \dots + \{\epsilon_0^2\} < a, \quad (5)$$

则结束训练.

由于将权向量趋于常向量作为训练结束的必要条件之一, 所以训练结束时, 由式(3), (5)可知

$$J = \sum_{j=0}^{N-1} \epsilon_j^2 V_j, \quad (6)$$

两边取期望运算得

$$EJ = \sum_{j=0}^{N-1} E\epsilon_j^2 V_j < a, \quad (7)$$

即

$$E\epsilon_j^2 = E(y_{k-j+l} - f_k(w, q, X_{k-j}))^2 = (a - \sum_{m=0, m \neq j}^{N-1} E\epsilon_m^2 v_m) / V_j < a / V_j, j = 0, 1, \dots, N - 1. \quad (8)$$

式(8)表明, 将预测器 $f(q, w, X_{k-j})$ 用于当今年份和各历史年份的均方误差期望值的上界, 分别为 a/V_j , $j = 0, 1, \dots, N - 1$. 由式(2)知, 越接近当前年份, 预测均方误差期望值上界将越小. 故式(7)既反映基于 k 年的预测器的要求,

$$E\epsilon_0^2 = E(y_{k+l} - f(w, q, X_k))^2 < a / V_0,$$

又反映时变性

$$E\epsilon_j^2 < a / V_j, j = 0, 1, \dots, N - 1, \\ a / V_j \leq a / V_{j+1}, j = 0, 1, \dots, N - 2.$$

在链式样本序列算法中, 误差调节函数 $\{V_j, j = 0, 1, \dots, N - 1\}$ 的选择基于对数据时变性特征的直接观察.

3) 检验对 q 的敏感性.

在小整数范围内, 选择不同的 q 值, 重复上面的过程. 如果预测结果对 q 的不同取值不敏感, 则肯定 q 的取值合适. 否则将重新选择 q 的选择范围.

3 实例——某城市 GDP 预测器(Example: GDP forecast for a city)

已知数据: 1978 ~ 1999 年的 GDP; 全社会固定资产投资(QGZ); 全市社会消费品零售总额(QSX); 外贸出口绝对值(WCJ); 商品零售物价指数(SLZ).

目的是立足 1998 年, 预测 1999 年的 GDP. 留取 1999 年的数据作为检验用. 其余构成原始样本: $\{P_j, j = 0, 1, \dots, 20\}$, $j = 0$ 对应 1998 年, $j = 20$ 对应 1979 年, $N = 20, l = 1$. 输入 6 维向量 $x_k = [QGZ, QSX, WCJ, SLZ, QGZ(-1), GDP(-1)]$, 然后按上节介绍的方法构成链式样本序列. 取误差调整函数

$$\{V_j = 20 - j, j = 0, 1, \dots, 19\}, N_2 = 200 > N.$$

取 $a = 0.0006$, 依次取 $q = 4, 5, \dots, 18$.

对于给定的 q 值, 分别用原始样本和链式样本进行训练并预测. 重复 8 次, 将预测结果按三类标准进行评价.

A 类: 收敛, 且相对预测误差 $< 0.5\%$, (此要求为经济部门所规定).

B 类: 收敛, 但相对预测误差 $> 0.5\%$.

C 类: 链式样本训练重复 12 次以上, 原始样本训练周期重复 90 次以上, (此时两种方法用于训练的总样本数大致相当), 仍未收敛.

对比的结果如图 1, 图 2, 图 3(a) 和 (b) 表示. 图 1 表

明采用链式样本对不同的值获得 A 类结果的都在 5 次以上,远高于原始样本方法.图 2 表明采用链式样本,获得 B 类结果的都在 3 次以下,远低于原始样本方法.获得 C 类情况两种方法大体相当.显然,链式重组样本,优于原始样本,这种优势对不同 q 值都如此.对不同的隐结点数 q ,用链式样本重组样本方法所得结果,没有太大的不同,说明对 q 的取值不敏感.

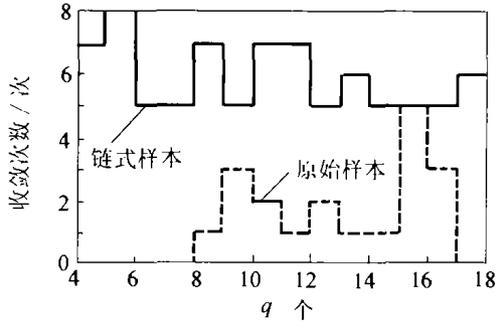


图 1 A 类次数比较

Fig. 1 Comparing the fit times of type A

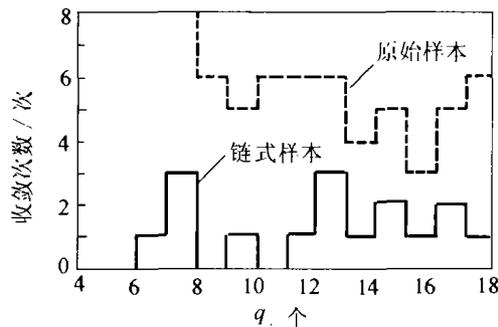


图 2 B 类次数比较

Fig. 2 Comparing the fit times of type B

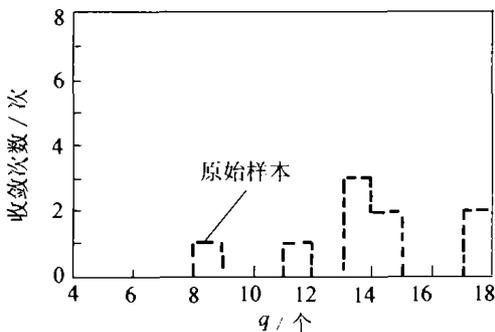


图 3(a) 用原始样本拟合不足的次数

Fig. 3(a) Fit times using original samples

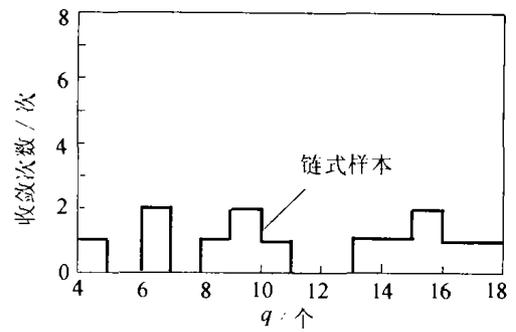


图 3(b) 用链式样本拟合不足的次数

Fig. 3(b) Fit times using chain style data

4 结论(Conclusion)

本文中提出的链式样本数据重组方法用于经济预测问题,较有效地解决了 BP 神经网络用于经济预测时所出现的样本数少、时变性特殊、隐结点数难以确定 3 个主要问题.实例明显地说明了该方法的有效性.链式样本数据重组训练方法,可推广用于其它领域预测和辨识问题.

参考文献(References):

- [1] JOSEPH B, WANG F H. Exploratory data analysis: A comparison of statistical methods with artificial neural networks [J]. *Computers & Chemical Engineering*, 1992, 16(4): 413 - 423.
- [2] 焦李成. 神经网络系统理论 [M]. 西安: 西安电子科技大学出版社, 1990.
(JIAO Licheng. *The Theory of Neural Networks* [M]. Xi'an: Xidian University Press, 1990.)
- [3] VEAUX R D. A comparison of two nonparametric estimation schemes: MARS and neural networks [J]. *Computers & Chemical Engineering*, 1993, 17(8): 819 - 837.

作者简介:

鄧跃茹 (1969 —), 女, 浙江大学电气工程学院博士, 主要从事复杂系统的智能控制, 混合动态系统建模、性能分析、控制、事件检测等方面的研究, E-mail: chinayrzi@hotmail.com;

朱维彰 (1944 —), 男, 1968 年毕业于北京大学物理系, 1981 年于北京理工大学获得工学硕士学位, 现任职于杭州电子工业学院自动化分院, 长期从事控制理论与应用、信号处理、智能控制等领域的教学与科研;

诸静 (1938 —), 男, 1962 年毕业于浙江大学电机系工业自动化专业, 现任浙江大学电气工程学院教授, 研究方向为复杂系统智能控制与系统集成、机器人控制、预测控制、模糊控制等.