

文章编号: 1001-0920(2003)01-0106-04

## 嵌入局部模型的 SOM 网络对混沌时间序列预测研究

朱家元, 虞建飞, 张恒喜

(空军工程大学 工程学院, 陕西 西安 710038)

**摘 要:** 针对混沌时间序列特征空间多变性的特点, 在 SOM 自组织神经网络中嵌入局部线性回归模型, 用于混沌时间序列的预测。该方法融合了局部线性预测的优点以及 SOM 网络数据快速聚类能力、可视化特征识别性质和拓扑保留映射特点, 既可减少运算时间和存储空间, 又能适应混沌时间序列的多变特征, 取得了较高的预测精度。

**关键词:** 局部线性回归模型; SOM 网络; 神经网络; 时间序列预测

**中图分类号:** TP183      **文献标识码:** A

## Prediction of chaotic time series based on self-organizing map embedded local models

ZHU Jia-yuan, YU Jian-fei, ZHANG Heng-xi

(Engineering College, Air Force Engineering University, Xi'an 710038, China)

**Abstract:** A new self-organizing map model with local linear models is presented, which is used to predict chaotic time series. The novel approach fuses linear prediction and capabilities of the SOM which is good at clustering, visualization analysis and topology preservation. The simulation shows that the approach achieves good results that reduce much computation time and large memory requirement, and also it can adapt characteristic variety of chaotic time series throughout the feature space.

**Key words:** Local linear regression model; Self-organizing map; Neural networks; Time series prediction

### 1 引 言

混沌时间序列预测在许多领域都有着重要的意义, 近年来受到人们的普遍关注。目前, 已有多种方法应用于混沌时间序列的预测, 如径向基函数插值法和多项式逼近法等<sup>[1,2]</sup>。此外, 许多学者还采用神经网络技术进行预测。文献[3~6]分别探讨了 BP 网络、Hebbian 网络、源分配网络和模糊神经网络在混沌时间序列预测中的应用问题。然而, 现有的方法算法复杂, 运行时间长, 特别是在处理大量数据时, 收敛速度慢, 预测精度不高。而基于以最近邻域理论为核心的局部模型的预测方法, 对于在特征空间的

多变性函数的预测精度较高。但它依赖于大量的例向量, 且占用大量的内存空间, 收敛速度慢。

为了克服这一缺陷, 本文尝试采用 SOM (Self-organizing Map) 神经网络对混沌时间序列进行预测。SOM 网络是一种自组织竞争人工神经网络, 具有良好的矢量量化功能和快速聚类能力, 而且能将高维数据拓扑保留映射到二维网格平面, 特征相似的矢量靠得较近, 网格平面的数据映射点具有类样本代表性, 即模式矢量。映射的二维网格平面易于可视化, 可以直观地观察到整个数据区域大体的分布情况, 便于掌握所有数据的大体本质特征, 有利于对

收稿日期: 2001-10-08; 修回日期: 2001-12-03。

基金项目: 国防预研基金资助项目(98J19 3 2 JB 3201)。

作者简介: 朱家元(1974—), 男, 湖南东安人, 博士生, 从事飞机系统工程、智能信息决策等研究; 张恒喜(1937—), 男, 江苏江堰人, 教授, 博士生导师, 从事飞机系统工程、优化与决策等研究。

不同特征混沌时间序列的预测。本文在输出映射网格平面的映射点聚集的模式矢量中, 嵌入局部线性回归模型的 SOM 网络, 对时间序列进行预测, 既可减少运算时间和存储空间, 又能适应混沌时间序列的多变特征, 取得了较高的预测精度。

## 2 基于嵌入局部线性回归模型的 SOM 神经网络

### 2.1 SOM 神经网络算法

输入样本用矢量  $x^p (p = 1, 2, \dots, k)$  表示, 每个样本的分量  $x_i^p$  与输入层的第  $i (i = 1, 2, \dots, n)$  个神经元相联。设与输出层第  $j$  个神经元之间的权为  $\mu_{ij}$ , 其输出为  $y_j$ , 它是一个二维平面。输入样本矢量  $x^p$  与权  $m_j (j = 1, 2, \dots, n_1)$  匹配的程度, 用欧氏距离  $d$  表示为

$$d(x^p, m_j) = \|x^p - m_j\| \quad (1)$$

其中

$$m_j = (\mu_{1j}, \mu_{2j}, \dots, \mu_{nj})^T$$

$$x^p = (x_1^p, x_2^p, \dots, x_n^p)^T$$

如果在输出层中有一个神经元与输入  $x^p$  匹配最好, 记为  $c$ , 则

$$d(x^p, m_c) = \min_j d(x^p, m_j) \quad (2)$$

其中  $m_c$  所对应的输出为  $y_c = \max_j y_j$ 。对权  $m_j$  进行修正, 有

$$m_j(t+1) = m_j(t) + \alpha(t) h_{bj}(t) (x - m_j(t)) \quad (3)$$

其中:  $\alpha(t)$  为学习率,  $h_{bj}(t)$  为邻域函数。采用高斯函数形式为

$$h_{bj}(t) = \exp\left(-\frac{r_b - r_j}{2\sigma^2(t)}\right) \quad (4)$$

其中:  $r_b$  和  $r_j$  分别为输出单元  $b$  和  $j$  的位置,  $\sigma(t)$  反映了邻域的范围。

### 2.2 局部线性回归模型构建

在时间序列预测中, 时间序列一般通过时间延迟嵌入状态空间, 即

$$X(n) = [x(n), x(n - \tau), \dots, x(n - (N - 1)\tau)] \quad (5)$$

其中:  $X(n)$  是嵌入矢量,  $x(n)$  是第  $n$  时间点的序列值,  $\tau$  是时延量,  $N$  是时间延迟序列的个数。通过嵌入矢量  $X(n)$  预测下一个序列值  $x(n + \tau)$ 。

首先对所预测的混沌时间序列, 通过式 (5) 建立一系列时序嵌入矢量, 分成训练集和测试集。将训练集输入到 SOM 网络进行训练, 获得二维网格平面映射点, 即模式矢量。每个嵌入矢量都可映射到一

个模式矢量上。每个模式矢量对应一些嵌入矢量, 即一个局部矢量集合。然后对局部矢量集合中的嵌入矢量建立线性回归预测模型

$$\hat{x}(n+1) = a_N + \sum_{i=0}^{N-1} a_i x(n-i) \quad (6)$$

其中:  $\hat{x}(n+1)$  是预测值,  $x(n-i)$  是嵌入矢量中的序列值,  $a_i$  是模型系数。通过模型 (6) 进行时间序列预测。

为使基于最小二乘估计的回归模型求解稳定, 回归模型中线性方程的数目至少应为  $N + 1$ 。因此, 需要对映射嵌入矢量数量少的模式矢量进行嵌入矢量合并。而 SOM 网络的拓扑保留特性使邻域矢量特征相似, 据此可对附近模式矢量进行数据集合, 这样对整个数据特征影响很小。本文确定的最少局部集合嵌入矢量数目为 12。

局部线性回归模型构建的具体步骤如下:

- 1) 从嵌入矢量训练集中取嵌入矢量, 输入到 SOM 网络进行训练, 形成模式矢量映射网格平面;
- 2) 根据模式矢量映射的特点, 构建局部矢量集合和局部模型;
- 3) 将预测测试矢量输入到训练好的 SOM 网络, 选择最佳匹配模式矢量;
- 4) 通过模式矢量所在的局部线性回归模型预测下一个序列值;
- 5) 将预测值嵌入测试集中的时序嵌入矢量, 构成新的嵌入矢量;
- 6) 将新嵌入矢量输入到 SOM 网络, 再次选择最佳模式矢量, 通过局部线性回归模型进一步预测下一个序列值。

以此规则循环, 进行时间序列预测。综合时间序列预测流程如图 1 所示。

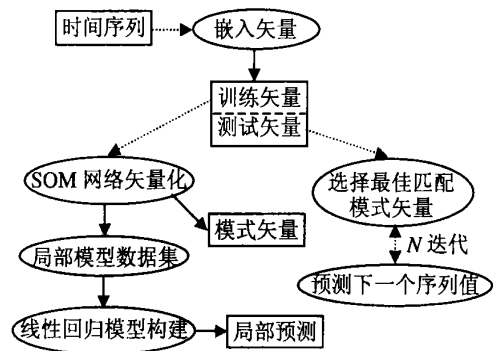


图 1 SOM 网络混沌时间序列预测流程

## 3 混沌时间序列预测算例

本文采用的时间序列由混沌 Mackey-Glass 差

分延迟方程产生, 该方程定义为

$$\frac{dx}{dt} = \beta x(t) + \frac{\alpha x(t - \delta)}{1 + x(t - \delta)^{10}} \quad (7)$$

其中:  $\beta = -0.1, \alpha = 0.2, \delta = 17$ 。采用 4 阶龙格-库塔法获得时间序列, 并按如下格式

$$X(n) = [x(n), x(n-6), x(n-12), x(n-18)] \quad (8)$$

抽取 3 001 对输入输出数据构成训练嵌入矢量集, 抽取 501 个输入市场数据构成测试嵌入矢量集。

在式(5)中, 令  $N = 4, \tau = 6$ , 则预测的序列值为  $x(n+6)$ 。对于每个测试矢量通过预测流程迭代 14 次, 便可获得序列  $x(n+84)$  的预测值。预测误差定义为

$$NRMSE = \sqrt{\frac{\sum_{i=0}^{N-1} (\hat{x}(i) - x(i))^2}{N \sigma_x^2}} \quad (9)$$

其中:  $\hat{x}(i)$  为  $x(i)$  的预测值,  $N$  为矢量数,  $\sigma_x^2$  为序列方差。

在整个 SOM 网络训练中迭代 100 次。初始邻域为整个映射网格平面的 1/2, 拓扑邻域为矩形, 初始学习率为 0.3, 学习率随网络迭代时间动态下降。

SOM 神经网络对于不同的数据规模需要调节映射网格数目, 以提高计算精度。为此, 在时间序列预测中采用不同大小的 SOM 网络映射网格(模式矢量)进行预测, 结果列于表 1。35 × 35 网格每个模式

表 1 不同模式矢量数对应的预测误差

模式矢量数	$x(n+6)$	$x(n+84)$
5 × 5	0.024	0.09
10 × 10	0.010	0.056
20 × 20	0.008	0.10
35 × 35	0.004 2	0.020
50 × 50	0.003 2	0.018
75 × 75	0.006 4	0.028




图 2 35 × 35 模式矢量的局部线性预测误差

矢量的局部线性预测误差结果如图 2 所示。

通过表 1 可以看出, 随着网格数目的增大(即模式矢量数增大),  $x(n+6)$  的预测误差逐渐减少。当网格数目为 35 × 35 和 50 × 50 时, 预测效果较好。但当模式矢量数目进一步增大时, 误差也随之变大。这是因为对于一定规模的数据, 过大的模式矢量数会增加计算量, 同时降低了 SOM 网络对矢量量化和预测的紧凑性, 从而引起误差的增大。鉴于这种情况, 本文针对不同的训练嵌入矢量数, 对时间序列预测进一步进行研究。不同训练矢量数对应的预测误差列于表 2。

表 2 不同训练矢量数对应的预测误差

训练矢量数	模式矢量数	$x(n+6)$	$x(n+84)$
501	35 × 35	0.028	0.11
1 001	35 × 35	0.008 8	0.032
3 001	35 × 35	0.004 2	0.020
10 001	35 × 35	0.002 4	0.016
10 001	100 × 100	0.001 6	0.007 2

通过表 1 和表 2 分析得出, 增大训练矢量, 预测精度可进一步提高, 而计算运行时间也相应增加。当训练矢量为 1 001, 模式矢量为 35 × 35 时,  $x(n+84)$  预测误差为 0.032; 当训练矢量为 3 001, 模式矢量为 10 × 10 时,  $x(n+84)$  预测误差为 0.056; 当训练矢量为 3 001, 模式矢量为 35 × 35 时, 预测误差减少到 0.020; 当训练矢量为 10 001, 模式矢量为 35 × 35 时, 预测误差进一步减少到 0.016。由此可见, 采用基于局部线性回归模型的 SOM 网络进行时间序列预测, 不同的模式矢量数和训练矢量数对预测精度的影响比较明显。因此, 采用该方法对混沌时间序列进行预测, 需要根据不同的时间序列采用不同的模式矢量规模进行试验, 这样才能获得较好的结果。

许多学者在时间序列的预测中做了大量工作。Deco 和 O bradovic<sup>[4]</sup> 采用 DHL 算法对  $x(n+85)$  的时间序列进行预测; Platt<sup>[5]</sup> 研究了 RAN 网络的预测; Litman 和 Ritter<sup>[7]</sup> 结合 DCA 和 LLM 进行预测; Lapedes 和 Farber<sup>[8]</sup> 采用标准 BP 网络对训练矢量集进行时间序列预测。本文将几种方法对时间序列预测的误差作了比较, 结果列于表 3。

通过表 3 可以看出, 采用基于局部线性回归模型的 SOM 神经网络对混沌时间序列的预测优于其他方法。

表 3 不同时间序列预测方法的预测误差

预测方法	训练 矢量数	$x(n+6)$	$x(n+84)$ 或 $(n+85)$
DHL	1 000		0.056
RAN	3 000		0.054
DCA + LLM	500		0.043
BP	500	0.02	0.06
SOM (35 × 35)	1 001	0.008 8	0.032
SOM (35 × 35)	3 001	0.004 2	0.020
SOM (10 × 10)	3001	0.010	0.056

## 4 结 语

SOM 神经网络具有快速处理高维数据的能力, 能把数据拓扑保留映射到二维网格平面。当输入模式变化时, 二维平面上对应的模式矢量也发生转移, 输入模式相似的映射模式矢量也相近。二维网格平面易于可视化, 有利于对不同特征混沌时间序列的预测。本文根据 SOM 网络的特点, 在 SOM 网络中嵌入局部线性回归模型, 对混沌预测时间序列预测进行研究, 并对混沌 Mackey-Glass 时间序列进行时间序列预测, 取得了较高的预测精度。预测结果表明了本文方法对时间序列的预测是可行而有效的。

(上接第 105 页)

## 5 结 语

本文给出的基于电子地图的修正方法, 可以改善目标的跟踪结果, 从而能更清晰地进行目标分辨, 与在有关系统中的联调结果十分接近, 这使得 TWS 系统的输出结果能更好地应用于战场侦察。从仿真中目标误跟而导致结果误判可以看出, 由于该算法依赖于跟踪算法的输出结果, 因此跟踪算法的好坏将直接影响此算法的结果。

### 参考文献(References):

- [1] Bar Shalom Y, Blair W D. *Multitarget-multisensor Tracking: Advanced Applications* [M]. Boston: Artech House, 2000
- [2] Bar Shalom Y, Li X R. *Multitarget-multisensor Track-*

### 参考文献(References):

- [1] Casdagli M. Nonlinear prediction of chaotic time series [J]. *Physica D*, 1989, 35: 335-356
- [2] Kugiumtzis D, L ingiarde O C, Christophersen N. Regularized local linear prediction of chaotic time series [J]. *Physica D*, 1998, 112: 344-360
- [3] Gencay R, Tung Liu. Nonlinear modeling and prediction with feedforward and recurrent networks [J]. *Physica D*, 1997, 108: 119-134
- [4] Deco G, Obradovic D. Decorrelated hebbian learning for clustering and function approximation [J]. *Neural Comput*, 1995, 7: 338-348
- [5] Platt J. Learning by combining memorization and gradient descent [J]. *Adv Neural Inform Proc Syst*, 1996
- [6] Maguire L P, Roche B, McGinnity T M, et al. Predicting a chaotic time series using a fuzzy neural network [J]. *Inform Sciences*, 1998, 112: 125-136
- [7] Littmann E, Ritter H. Learning and generalization in cascade network architectures [J]. *Neural Comput*, 1996, 8(7): 1521-1539
- [8] Lapedes A, Farber R. Nonlinear signal processing using neural networks: Prediction and system modelling [R]. Los Alamos, 1987.

*ing: Principles and Techniques* [M]. Storrs: YBS Publishing, 1995

- [3] 潘泉. 自适应目标跟踪算法研究 [D]. 西安: 西北工业大学, 1997.
- [4] Kirubarajan T, Bar Shalom Y, Pattipati K R, et al. Ground target tracking with topography-based variable structure MM estimator [A]. *Proc SPIE Conf Signal Data Proc of Small targets* [C]. Orlando, 1998: 222-233
- [5] Kirubarajan T, Bar Shalom Y, Pattipati K R, et al. Ground target tracking with topography based variable structure MM estimator [J]. *IEEE Trans A eros Electr Syst*, 2000, 36(1): 26-46