

交通流序列的 Volterra 自适应预测

张玉梅¹, 马 骥²

(1. 陕西师范大学计算机科学学院, 西安 710062; 2. 西安工程大学计算机科学学院, 西安 710048)

摘 要: 基于混沌动力系统的相空间重构和非线性系统的 Volterra 级数, 构建交通流的 Volterra 自适应预测模型。在应用小数据量法判定交通流存在混沌特性的前提下, 分别用平均互信息法和虚假邻点法选取延滞时间和嵌入维数以实现交通流时间序列的相空间重构。通过 Volterra 级数展开式建立非线性预测模型, 采用 LMS 自适应算法实时调整模型的系数。以 Volterra 自适应预测模型对实际采集的高速公路交通流量时间序列及模拟产生的 Chens 和 Duffing 混沌时间序列进行仿真研究。结果表明, 该模型能够较准确地预测交通流量时间序列和低维混沌时间序列。

关键词: 短时交通流; 预测模型; Volterra 级数; 相空间重构; 混沌

Volterra Adaptive Prediction of Traffic Flow Sequence

ZHANG Yu-mei¹, MA Su²

(1. College of Computer Science, Shaanxi Normal University, Xi'an 710062, China;

2. College of Computer Science, Xi'an Polytechnic University, Xi'an 710048, China)

【Abstract】 Based on phase space reconstruction of chaos dynamic system and Volterra series for nonlinear system, Volterra adaptive prediction model for traffic flow is constructed. On the premise that small data set method is used to determine that chaos exists in traffic flow time series, this paper respectively employs average mutual information method and false nearest neighbor technique to choose delay time and embedding dimension so as to perform phase space reconstruction for traffic flow data. Nonlinear prediction model, whose coefficients are real-time updated by LMS adaptive algorithm is constructed by applying Volterra series extensions. It applies this Volterra prediction model to performing simulations for the real measured expressway traffic flow data and chaotic time series generated by Chens and Duffing. Experimental results show that the proposed Volterra adaptive prediction model is capable of effectively predicting traffic flow time sequence and low-dimensional chaotic time sequence.

【Key words】 short-term traffic flow; prediction model; Volterra series; phase space reconstruction; chaos

DOI: 10.3969/j.issn.1000-3428.2011.16.063

1 概述

诱导和控制是智能交通系统(Intelligent Transportation System, ITS)的重要组成部分。实时准确的交通流预测是实现交通诱导和控制的前提与关键。由于交通诱导和控制对实时性有较高的要求: 交通控制的最大周期是 2.5 min~3 min, 交通诱导的周期一般为 5 min。因此, 如何在 5 min 内准确地预测交通流是实现 ITS 的关键。文献[1]证明了交通流时间序列具有混沌特性。基于嵌入定理^[2]及相空间重构思想^[3], 已提出许多混沌时间序列的非线性预测方法, 主要分为全局预测法、局域预测法和自适应预测法。与全局预测、局域预测相比, 自适应预测有更多的优点, 已成为当今研究的热点。本文将 Volterra 级数应用于交通流量时间序列预测中, 建立了交通流量的 Volterra 自适应预测模型, 并应用该模型对实测高速公路交通流序列和 2 种典型混沌序列进行了仿真研究。

2 短时交通流预测框架

本文在相空间重构和 Volterra 级数的基础上提出短时交通流预测方法, 预测过程如图 1 所示。首先通过观测从实际的交通系统中获得交通流量时间序列 $\{q(n)\}$ 。然后适当选取嵌入维数 m 和延滞时间 τ , 对时间序列 $\{q(n)\}$ 进行相空间重构, 得到 $q(n)$ 。只要嵌入维数和延滞时间选取合适, 交通动力系统的几何特征与重构的 m 维状态空间的几何特征是等价的。此时应用 Volterra 自适应预测法在重构的状态空间中对交通流量进行预测, 所获得交通流量预测信息能为交通诱导和控制提供准确的参考。




图1 短时交通流预测过程

3 交通流时间序列的相空间重构

相空间重构的基本原理是 Takens 的延迟嵌入定理^[2], 即只要适当选取嵌入维数 m 和延滞时间 τ , 原混沌动力系统的几何特征与重构的 m 维状态空间的几何特征便是等价的, 它们具有相同的拓扑结构。这意味着可把预测问题转化为相空间中的一个短的演化过程来讨论, 从而为混沌时间序列的预测奠定坚实的理论基础^[4]。

设观测的交通流量时间序列为:

$$\{q(n)\}_{n=1}^N, q(n) = q(t_0 + n\Delta t) \quad (1)$$

其中, t_0 表示初始时间; Δt 为采样时间间隔。选择合适的嵌入维数 m 和延滞时间 τ , 由式(1)重构一个 m 维的状态向量:

基金项目: 陕西省自然科学基金资助项目(2008k07); 陕西师范大学青年科技基金资助项目(200901001)

作者简介: 张玉梅(1977—), 女, 讲师、博士, 主研方向: 混沌理论, 智能交通控制; 马 骥, 讲师

收稿日期: 2010-12-26 **E-mail:** zym0910@tom.com

$$q(n)=[q(n),q(n-\tau),L,q(n-(m-1)\tau)]^T$$

$$n=N_0,N_{0+1},L,N$$

其中, $N_0=(m-1)\tau+1$; $\hat{q}(n)$ 为相点; m 维序列 $\{q(n)|n=N_0,N_{0+1},L,N\}$ 构成一个相型, 它表示交通流在某一瞬间的状态。按时间增长的顺序将其相连, 即可描述交通流在 m 维相空间中的演化轨迹。此时状态空间 $q(n) \rightarrow q(n+1)$ 的演化反映了交通系统的演化, 这样就可以根据历史数据进行预测。

文献[4]介绍了多种延滞时间 τ 和嵌入维数 m 的选取方法。其中, 自相关函数法是较简单的寻找延滞时间 τ 的方法; 互信息方法[5]是估计延滞时间 τ 的有效方法, 在相空间重构中有广泛的应用。而选取嵌入维数 m 最常用的方法有试算法和虚假邻点法[6]。本文分别采用互信息法和虚假邻点法选取延滞时间 τ 和嵌入维数 m 。

4 Volterra 自适应预测模型

混沌序列预测的基础是相空间重构理论。假设观测到的交通流量时间序列为 $\{q(n)\}_{n=1}^N$, 则在状态空间中重构的一点可表示为 $q(n)=[q(n),q(n-\tau),L,q(n-(m-1)\tau)]$ 。由 Takens 定理可知, 混沌序列的预测本质上是一个动力系统的逆问题, 即通过动力系统的状态反过来重构系统的动力学模型 $F(\cdot)$, 即建立 $q(n+T)=F(q(n))$, 其中, T 为前向预测步长($T>0$)。本文中为单步预测, 因此, 取 $T=1$ 。

构造一个非线性函数逼近 $F(\cdot)$ 有许多方法。实际中大量的非线性系统用 Volterra 级数表征[7]。因此, 可用 Volterra 级数展开式构造混沌时间序列的非线性预测模型 $F(\cdot)$ 。

设模型的输入为 $q(n)=[q(n),q(n-\tau),L,q(n-(m-1)\tau)]$, 输出为 $y(n)=q(n+1)$, 则用于混沌时间序列预测的 Volterra 级数展开式为:

$$q(n+1)=F(q(n))=h_0+\sum_{k=1}^{+\infty}y_k(n)=$$

$$h_0+\sum_{m_1=0}^{+\infty}h_1(m_1)q(n-m_1\tau)+$$

$$\sum_{m_1=0}^{+\infty}\sum_{m_2=0}^{+\infty}h_2(m_1,m_2)q(n-m_1\tau)q(n-m_2\tau)+L+$$

$$\sum_{m_1=0}^{+\infty}\sum_{m_2=0}^{+\infty}L\sum_{m_p=0}^{+\infty}h_p(m_1,m_2,L,m_p)q(n-m_1\tau)Lq(n-m_p\tau)+L$$

其中, $h_p(m_1,m_2,L,m_p)$ 为 p 阶 Volterra 核。在实际应用中, 这种无穷级数展开式难以实现, 必须采用有限截断和有限次求和的形式[3], 最常用的是二阶截断求和形式:

$$\hat{q}(n+1)=h_0+\sum_{m_1=0}^{N_1-1}h_1(m_1)q(n-m_1\tau)+$$

$$\sum_{m_1=0}^{N_1-1}\sum_{m_2=0}^{N_2-1}h_2(m_1,m_2)q(n-m_1\tau)q(n-m_2\tau)$$

由 Takens 嵌入定理可知: 一个混沌时间序列要完全描述原动力系统的动态行为, 至少需要 $m>2d+1$ (d 是动力系统的维数)个变量。取 $N_1=N_2=m$, 因此, 用于交通流量混沌序列的二阶 Volterra 预测模型为:

$$\hat{q}(n+1)=h_0+\sum_{i=0}^{m-1}h_1(i)q(n-i\tau)+$$

$$\sum_{i=0}^{m-1}\sum_{j=0}^{m-1}h_2(i,j)q(n-i\tau)q(n-j\tau) \quad (2)$$

令:

$$H(n)=[h_0,h_1(0),h_1(1),L,h_1(m-1),h_2(0,0),$$

$$h_2(0,1),L,h_2(m-1,m-1)]^T$$

$$Q(n)=[1,q(n),q(n-\tau),L,q(n-(m-1)\tau),$$

$$q^2(n),q(n)q(n-\tau),L,q^2(n-(m-1)\tau)]^T$$

因此, 式(2)可表示为:

$$\hat{q}(n+1)=H^T(n)Q(n) \quad (3)$$

Volterra 预测模型采用最小均方(Least Mean Square, LMS)自适应算法实时调整模型的系数。当模型系数矢量为 $H(n)$ 、输入信号矢量为 $Q(n)$ 时, LMS 算法可描述如下[8]:

$$e^2(n)=d^2(n)-2d(n)H^T(n)Q(n)+H^T(n)Q(n)Q^T(n)H(n)$$

$$H(n+1)=H(n)-2\mu e(n)\frac{\partial e(n)}{\partial H(n)}=H(n)+2\mu e(n)Q(n)$$

其中, μ 为收敛步长($0<\mu<2$); $d(n)$ 为理想值, 本文取 $d(n)=q(n)$ 。

5 实验结果及分析

本节就 Volterra 自适应预测模型对实际采集的高速公路交通流量和模拟产生的混沌时间序列进行仿真研究。首先按式(4)对时间序列进行归一化处理:

$$x(i)=\frac{y(i)-\frac{1}{N}\sum_{k=1}^Ny(k)}{\max(y(i))-\min(y(i))} \quad (4)$$

其中, $\{y(i)\}$ 为原时间序列; $\{x(i)\}$ 为归一化的时间序列; N 为序列长度。在本文中, 以预测的均方误差(Mse)作为评判标准, 其定义为:

$$Mse=\frac{1}{N_p}\sum_{k=1}^{N_p}[x(k)-\hat{x}(k)]^2 \quad (5)$$

其中, $x(k)$ 为实际值; $\hat{x}(k)$ 为预测值; N_p 为预测序列长度。下面给出二阶 Volterra 自适应预测模型对实测交通流量和混沌序列进行仿真的结果。

5.1 实测交通流量预测

实验中的交通流量数据来自西安市环城高速公路某路段, 采样时间从 2006 年 4 月 2 日起连续观测 10 个工作日, 观测时间为 7:00 至 10:00, 每 5 分钟记录一次数据, 共产生 360 个数据。首先对数据进行混沌特性判定, 通过小数据量法得到最大 Lyapunov 指数 $\lambda_1=0.610$, 是正数, 表明系统具有混沌特性。然后对交通流量时间序列 $\{q(n)\}_{n=1}^{220}$ 利用互信息最小法计算出最佳延滞时间 $\tau=7$; 利用虚假邻点法得到最小嵌入维数 $m=4$ 。对交通流量时间序列进行相空间重构, 得到:

$$q(n)=(q(n),q(n-7),q(n-14),q(n-21))$$

取 $\{q(n)\}_{n=1}^{220}$ 作为训练样本用于训练二阶 Volterra 自适应预测模型, 然后对交通流量时间序列的后 140 个数据进行预测, 即预测 $\{q(220+p)\}_{p=1}^{140}$, 预测结果如图 2 所示。





图 2 二阶自适应预测模型对实测交通流量时间序列的预测结果

从图 2 可以看出, 交通流量的预测值和真实值变化趋势是一致的。预测的均方误差 $Mse=2.332\times 10^{-3}$, 表明预测结果能够很好地反映交通流量变化的趋势和规律, 预测精度较高, 完全可以满足交通控制和诱导所需的预测精度。


5.2 Chens 和 Duffing 混沌时间序列预测

实验中混沌映射按设定初始值直接迭代, Chens 系统的积分步长取 0.01, Duffing 取 0.05。利用四阶 Runge-Kutta 积

分法计算出包含 8 000 个数据的仿真时间序列。为减小瞬态影响, 去掉前 6 000 个数据, 剩下的 2 000 个数据作为实验数据, 其中, 前 500 个数据作为训练样本; 后 1 500 个作为测试样本。由于这 2 种序列均具有混沌特性, 因此不用小数据量法对其进行混沌特性判定, 而是直接对其进行相空间重构。然后应用本文提出的预测方法对这 2 种混沌序列进行预测。图 3 和图 4 分别为应用二阶 Volterra 自适应预测模型对 Chens 和 Duffing 混沌时间序列的预测结果。




(a) 真实值 $x(n)$ 与预测值 $x_p(n)$




(b) 绝对误差预测值

图 3 二阶自适应预测模型对 Chens 混沌序列的预测结果



(a) 真实值 $x(n)$ 与预测值 $x_p(n)$



(b) 绝对误差预测值

图 4 二阶自适应预测模型对 Duffing 混沌序列的预测结果

可以看出, 该模型对这 2 种混沌时间序列均有良好的预测结果。经计算得 Chens 序列预测的均方误差 $Mse = 8.067 6 \times 10^{-4}$, Duffing 序列的 $Mse = 7.773 2 \times 10^{-5}$ 。

6 结束语

本文基于混沌动力系统相空间的延迟坐标重构, 采用 Volterra 级数及 LMS 自适应算法构造了交通流时间序列的非线性自适应预测模型, 并对实测高速公路交通流数据和 2 种典型混沌时间序列进行仿真研究。实验结果表明, 构建的二阶 Volterra 自适应预测模型能够很好地反映交通流量变化的趋势和规律, 预测精度较高。因此, 对于交通诱导和控制而言, 本文方法为准确预测交通流量提供了一种有益的尝试。同时, 对 2 种典型混沌时间序列的预测结果表明, 本文方法同样适用于混沌时间序列的预测。

参考文献

- [1] Low D J, Addison P S. Chaos in a Car-following Model with a Desired Headway Time[C]//Proceedings of the 30th ISATA Conference. Florence, Italy: [s. n.], 1997: 175-182.
- [2] Takens F. On the Numerical Determination of the Dimension of an Attractor[M]//Braaksma B L J. Dynamical Systems and Turbulence. [S. l.]: Springer-Verlag, 1981.
- [3] 张家树, 肖先赐. 混沌时间序列的 Volterra 自适应预测[J]. 物理学报, 2000, 49(3): 403-408.
- [4] 王海燕, 卢 山. 非线性时间序列分析及其应用[M]. 北京: 科学出版社, 2006.
- [5] Fraser A M, Swinney H. Independent Coordinates for Strange Attractors from Mutual Information[J]. Physical Review A, 1986, 33(2): 1134-1140.
- [6] Kennel M B, Brown R, Abarbanel H D I. Determining Embedding Dimension for Phase Space Reconstruction Using a Geometrical Construction[J]. Physical Review A, 1992, 45(6): 3403-3411.
- [7] Standberg I W. On Volterra Expansions for Time Varying Nonlinear Systems[J]. IEEE Transactions on Circuits and Systems, 1983, 30(2): 61-67.
- [8] Douglas S C, Meng T H Y. Normalized Data Nonlinearities for LMS Adaptation[J]. IEEE Transactions on Signal Processing, 1994, 42(6): 1352-1365.

编辑 张正兴

(上接第 184 页)

4 结束语

基于 PCA 和改进 K 均值算法的动作电位特征分类方法, 有效地实现了大鼠初级视觉皮层 V1 区神经元动作电位的分类, 提高了动作电位分类的准确率及算法稳定性, 具有分类正确率高、抗噪性能强等优势, 可为下一步研究视觉神经系统的信息处理机制提供可靠的分析基础。

参考文献

- [1] Dayan P, Abbott L F. Theoretical Neuroscience[M]. [S. l.]: MIT Press, 2001.
- [2] Quiroga R O. Spike Sorting[J]. Scholarpedia, 2007, 2(12): 3583.
- [3] Segev R, Goodhouse J, Puchalla J, et al. Recording Spikes from a Large Fraction of the Ganglion Cells in a Retinal Patch[J]. Nature

Neuroscience, 2004, 7(10): 1155-1162.

- [4] 刘海龙. MEA 信号动作电位的小波变换分类[J]. 计算机与数字工程, 2006, 34(4): 35-38.
- [5] Shoham S, Fellows M R, Normann R A. Robust, Automatic Spike Sorting Using Mixtures of Multivariate T-distributions[J]. Journal of Neuroscience Methods, 2003, 127(2): 111-122.
- [6] Dai Jianhua, Liu Xiaochun, Zhang Shaomin, et al. Neuronal Spike Sorting Based on 2-stage RBF Networks[C]//Proc. of the 2nd International Conference on Future Generation Communication and Networking. [S. l.]: IEEE Computer Society, 2008: 47-50.
- [7] 韩成茂. 基于类内加权平均值的模块 PCA 算法[J]. 计算机工程, 2009, 35(22): 194-195, 199.

编辑 索书志

