

交通流量 VNNTF 神经网络模型 多步预测研究

殷礼胜¹ 何怡刚¹ 董学平¹ 鲁照权¹

摘要 研究了 VNNTF 神经网络 (Volterra neural network traffic flow model, VNNTF) 交通流量混沌时间序列多步预测问题. 通过分析比较交通流量混沌时间序列相空间重构的嵌入维数和 Volterra 离散模型之间的关系, 给出了确定交通流量 Volterra 级数模型截断阶数和截断项数的方法, 并在此基础上建立了 VNNTF 神经网络交通流量时间序列模型; 设计了交通流量 Volterra 神经网络的快速学习算法; 最后, 利用交通流量混沌时间序列对 VNNTF 网络模型, Volterra 预测滤波器和 BP 网络进行了多步预测实验, 比较了多步预测结果的仿真图、绝对误差的柱状图以及归一化后的方均根; 实验结果表明 VNNTF 神经网络的多步预测性能明显优于 Volterra 预测滤波器和 BP 神经网络.

关键词 相空间重构, 泛函级数, 多步预测, VNN 神经网络, 算法, 混沌引用格式 殷礼胜, 何怡刚, 董学平, 鲁照权. 交通流量 VNNTF 神经网络模型多步预测研究. 自动化学报, 2014, 40(9): 2066–2072

DOI 10.3724/SP.J.1004.2014.02066

Research on the Multi-step Prediction of Volterra Neural Network for Traffic Flow

YIN Li-Sheng¹ HE Yi-Gang¹ DONG Xue-Ping¹
LU Zhao-Quan¹

Abstract This paper studies multi-step prediction of traffic flow chaotic time series based on Volterra neural network traffic flow model (VNNTF). Firstly, by analyzing the relationship between the embedding dimension of phase space reconstruction of traffic flow chaotic time series and Volterra discrete model, we give the method to determine the truncation order and items of Volterra series. Secondly, based on the first step, we build the VNNTF neural networks model of chaos time series and design the fast learning algorithm of Volterra neural network traffic flow. Thirdly, we describe multi-step prediction experiments based on chaotic time series VNNTF traffic network model, Volterra prediction filter and BP networks. Finally, we compare the multi-step prediction simulation diagram with the absolute error histogram and normalized root mean square are compared. The experimental results show that the VNNTF neural network multi-step prediction performance is significantly better than those of the Volterra filter and BP neural network.

Key words Phase space reconstruction, functional series, multi-step prediction, Volterra neural network (VNN) neural networks, algorithm, chaos

Citation Yin Li-Sheng, He Yi-Gang, Dong Xue-Ping, Lu Zhao-Quan. Research on the multi-step prediction of Volterra neural network for traffic flow. *Acta Automatica Sinica*, 2014, 40(9): 2066–2072

收稿日期 2013-06-10 录用日期 2013-11-26
Manuscript received June 10, 2013; accepted November 26, 2013
国家杰出青年科学基金 (50925727), 教育部科学技术研究重大项目 (313018), 安徽省高校自然科学基金重点项目 (KJ2012A219), 中国博士后科学基金 (2013M541823) 资助
Supported by National Natural Science Funds of China for Distinguished Young Scholar (50925727), (Key Grant) Project of Chinese Ministry of Education (313018), Natural Science Foundation of Univ

非线性系统的 Volterra 级数模型分析方法对记忆性不严格要求, 被称作“有记忆效应的 Taylor 级数”, 具有高精度和物理意义明确的优点, 已成为研究非线性系统的非常有效的非参数模型之一^[1–4]. 因为交通流量混沌时间序列具备有限记忆功能的特征, 所以 Volterra 泛函级数变成了国内外相关领域研究人员进行交通流量泛函系统辨识研究的一种有力工具. 许多学者和科技开发人员提出了很多 Volterra 辨识算法, 但是建立非线性系统 Volterra 级数模型^[5–9], 不是一件容易的事情. 这是因为 Volterra 的级数有一个很明显的缺点, 就是要想取得满意的精度, 需要相当多的被估计参数. 高阶的核函数估计是其面临的一个最大的困难. 这在很大程度上制约了 Volterra 泛函级数模型的有效应用, 有时为了计算上的简单与方便, 避免求解高阶 Volterra 核函数的困难, 而刻意地对 Volterra 泛函模型进行低阶数的截断, 结果就导致了建模的不精确, 影响模型的预测性能^[10].

随着计算机技术的迅猛发展, 神经网络更加深入而广泛地应用于非线性系统^[10–14]. 神经网络具有自适应性, 并行性和容错性等特点, 也具有逼近任意非线性函数的能力. 基于这些优点, 非线性系统的神经网络模型得到了非常广泛的应用^[15–17]. 因为 3 层前馈人工神经网络 (Artificial neural network, ANN) 模型和 Volterra 级数存在等价性, 如何结合交通流量的混沌特性, 利用 Volterra 泛函模型精确建模和前馈 ANN 模型学习训练神经网络的特点, 克服求解 Volterra 高阶核函数的困难和前馈 ANN 神经网络建模的盲目性, 具有一定的研究意义.

本文通过分析 3 层前馈 ANN 神经网络模型和 Volterra 级数的等价性^[18–21]. 建立了交通流量混沌时间序列 Volterra 神经网络模型 (Volterra neural network traffic flow model, VNNTF), 并给出了一种对应的快速学习算法. 实际上, VNNIF 神经网络模型汲取了 Volterra 级数精确建模和前馈 ANN 神经网络训练学习的优点, 有效地保证了交通流量混沌时间序列预测模型的准确性和算法的可行性, 也就是说, 克服了 Volterra 级数模型求解高阶 Volterra 核函数的困难和前馈 ANN 神经网络建模的盲目性, 在实际的交通流量预测中取得了较好的应用效果.

1 交通流量混沌时间序列 Volterra 模型

对于非线性系统, Volterra 离散化模型如下:

$$y(n) = \sum_i \sum_{l_1, \dots, l_i=0}^{\infty} h_i(l_1, \dots, l_i) x(n-l_1) x(n-l_i) \quad (1)$$

这里, $n, l_i \in \mathbf{R}$, $x(n-l_i)$ 为非线性系统的输入, $y(n)$ 为非线性系统的输出, $h_i(l_1, \dots, l_i)$ ($i = 1, 2, \dots, n$) 是 i 阶 Volterra 核函数.

1.1 交通流量混沌时间序列 Volterra 模型的截断阶数确定

若采样得到的交通流量混沌时间序列为 $\{x(t)|t = 1, 2, 3, \dots\}$, 对其进行混沌相空间重构, 可以得到非线性系统的输入为 $x(t), x(t+\tau), x(t+2\tau), \dots, x(t+(m-1)\tau)$,

ersities of Anhui Province (KJ2012A219), and China Postdoctoral Science Foundation (2013M541823)

本文责任编辑 刘德荣

Recommended by Associate Editor LIU De-Rong

1. 合肥工业大学电气与自动化工程学院 合肥 230009

1. School of Electrical Engineering and Automation, Hefei University of Technology, Hefei 230009

m 为嵌入维数, 即重构相空间的维数, τ 为延迟时间, 实际上, m 项和 Volterra 离散化模型中的有限阶数相对应, 而且因为所预测的交通流量混沌时间序列是在这 m 项的基础上进行预测, 通常情况下, m 的取值不会很大, 所以可以将交通流量相空间重构模型用 m 阶截断 Volterra 级数模型进行表征, 具体如下:

$$x(t' + T) = F(\mathbf{X}(t)) = h_0 + \sum_{l_0=0}^{\infty} h_1(l_0)x(t - l_0\tau) + \sum_{l_0=0}^{\infty} \sum_{l_2=0}^{\infty} h_2(l_1, l_2)x(t - l_1\tau)x(t - l_2\tau) + \dots + \sum_{l_0=0}^{\infty} \sum_{l_2=0}^{\infty} \dots \sum_{l_p=0}^{\infty} [h_m(l_1, l_2, \dots, l_m) \times x(t - l_1\tau)x(t - l_2\tau) \dots x(t - l_m\tau)] \quad (2)$$

其中, $h_m(l_1, l_2, \dots, l_m)x(t - l\tau)$ 为 m 阶 Volterra 核函数, $t' = t + (m - 1)\tau$, $T (T > 0)$ 为前向多步预测的步长, 从理论上说, 式 (2) 能精确地对交通流量进行预测, 但由于其具有无穷多项, 在实际中很难实现, Volterra 级数模型必须采用有限阶截断以及有限项求和的形式. 由于 Volterra 级数总项数个数呈幂指数增长. 在实际当中, 截断阶数一般取二阶截断或者三阶截断.

1.2 交通流量混沌时间序列 Volterra 模型的截断项数确定

交通流量 Volterra 级数模型的表达形式为式 (2), 假设其截断的有限项求和的形式如下:

$$x(t' + T) = F(\mathbf{X}(t)) = h_0 + \sum_{l_0=0}^{N_1-1} h_1(l_0)x(t - l_0\tau) + \sum_{l_0=0}^{N_2-1} \sum_{l_2=0}^{N_2-1} h_2(l_1, l_2)x(t - l_1\tau)x(t - l_2\tau) + \dots + \sum_{l_0=0}^{N_m-1} \sum_{l_2=0}^{N_m-1} \dots \sum_{l_p=0}^{N_m-1} [h_m(l_1, l_2, \dots, l_m) \times x(t - l_1\tau)x(t - l_2\tau) \dots x(t - l_m\tau)] \quad (3)$$

对于交通流量混沌时间序列, 如果 $x(t)$, $y(t)$ 分别是满足交通流量泛函系统 $f(t, x(t'), t' \leq t)$ 的输入与输出信号, 那么 $f(t, x(t'), t' \leq t)$ 中的交通流量的输入信号 $x(t)$ 满足以下条件:

- 1) $x(t)$ 满足因果关系, 也就是当 $t < 0$ 时, $x(t) = 0$.
- 2) 交通流量泛函系统 $f(t, x(t'), t' \leq t)$ 具有有限记忆性, 即在离 t 很远的时间 t_0 , 也就是 $t_0 \rightarrow \infty$, $x(t - t_0)$ 对 $y(t)$ 不产生影响, 即 $y(t)$ 的预测值与 $x(t - t_0)$ 无关.

如果用 $x(t' + T)$ 表示输入信号 $x(t)$ 及其相关延迟时间信号 τ 的下一步输出, 那么

$$x(t' + T) = f(x_{l_1}, x_{l_2}, \dots, x_{N_{l_i}}) = h_0 + \sum_{l_0=0}^{N_{l_1}-1} h_1(l_0)x(t - l_0\tau) + \sum_{l_0=0}^{N_2-1} \sum_{l_2=0}^{N_2-1} h_2(l_1, l_2)x(t - l_1\tau)x(t - l_2\tau) + \dots$$

$$\sum_{l_0=0}^{N_m-1} \sum_{l_2=0}^{N_m-1} \sum_{l_3=0}^{N_m-1} \dots \sum_{l_p=0}^{N_m-1} [h_m(l_1, l_2, \dots, l_m) \times x(t - l_1\tau)x(t - l_2\tau) \dots x(t - l_m\tau)] \quad (4)$$

这里记 $N_{\max} = \max(N_{l_1}, N_{l_2}, N_{l_3}, \dots, N_{l_i}) (i = 1, 2, 3, \dots)$, 当 $n \geq N_{\max}$ 时, 同样可以满足输入交通流量信号 $x_{l_i} = x(t - l_i\tau)$ 对 $y(t)$ 没有影响, 即满足有限记忆性, 则式 (4) 可记为

$$x(t' + T) = f(x_{l_1}, x_{l_2}, \dots, x_{N_{l_i}}) = h_0 + \sum_{l_0=0}^{N_{\max}-1} h_1(l_0)x(t - l_0\tau) + \sum_{l_0=0}^{N_{\max}-1} \sum_{l_2=0}^{N_{\max}-1} h_2(l_1, l_2)x(t - l_1\tau)x(t - l_2\tau) + \sum_{l_0=0}^{N_{\max}-1} \sum_{l_2=0}^{N_{\max}-1} \sum_{l_3=0}^{N_{\max}-1} [h_3(l_1, l_2, l_3)x(t - l_1\tau) \times x(t - l_2\tau)x(t - l_3\tau)] + \dots \quad (5)$$

根据以上交通流量泛函系统 $f(t, x(t'), t' \leq t)$ 的分析, 可以知道, 其交通流量预测结果的幂级数展开式中的项只与 $x(t)$ 及其全部延迟时间信号的一次幂形式的全部乘积组合有关系, 也就是说 $N_{\max} = \max(N_{l_1}, N_{l_2}, N_{l_3}, \dots, N_{l_i}) (i = 1, 2, 3, \dots)$ 的取值只与 $x(t)$ 及其全部延迟时间信号的个数有关系, 也就是交通流量混沌时间序列的相空间的最小嵌入维数 m , 即:

$$N_{\max} = \max(N_{l_1}, N_{l_2}, N_{l_3}, \dots, N_{l_i}) = m$$

2 交通流量混沌时间序列 Volterra 神经网络模型 (VNNTF)

2.1 非线性系统的 ANN 网络表示方法

已证明任意一个连续有界的非线性系统可以用一个含有隐层的 BP 神经网络任意逼近, 所以可建立一个单输出单隐层的三层反传 BP 神经网络来逼近非线性系统, 其结构如图 1 所示:

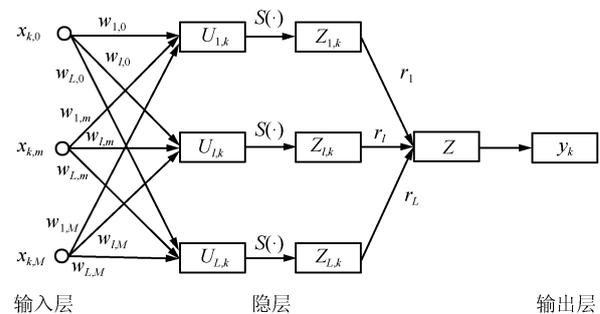


图 1 对应 $M + 1$ 维输入的单输出三层神经网络模型
Fig. 1 Three layer neural networks in response to $M + 1$ input and single output system

在图 1 中, n 时刻的输入向量 $\mathbf{x}_k^T = [x_{k,0}, x_{k,1}, \dots, x_{k,m}]$ 可以通过 $x(k)$ 经延时获取, 其中 $x_{k,m} = x(k - m)$, 那么, 隐

层单元的第 l ($l = 1, 2, \dots, L$) 个输出可以表示为

$$Z_{l,k} = S_l(u_{l,k}), \quad u_{l,k} = \sum_{m=0}^M w_{l,m} x_{k,m} \quad (6)$$

将隐层单元的各个输出 $Z_{l,k}$ 在阈值 θ_l 处展开成 Taylor 级数, 若输出单元是线性求和形式, 则神经网络的输出可以表示为

$$y_k = \sum_{l=1}^L r_l Z_{l,k} = \sum_{l=1}^L r_l \left[\sum_{i=0}^{\infty} d_i(\theta_l) u_{l,k}^i \right] = \sum_{l=1}^L r_l \sum_{i=0}^{\infty} d_i(\theta_l) \cdot \sum_{m_1=0}^M \dots \sum_{m_i=0}^M [W_{l,m_1} \dots W_{l,m_i} \times W_{k,m_1} \dots W_{k,m_i}] \quad (7)$$

其中, $d_i(\theta_l)$ 为展开后的各项系数.

2.2 交通流量 Volterra 神经网络模型

通过分析比较三层 BP 神经网络式 (7) 和交通流量混沌时间序列 Volterra 级数模型式 (5), 如果将 BP 神经网络式 (7) 中输入向量 $\mathbf{x}_k^T = [x_{k,0}, x_{k,1}, \dots, x_{k,M}]$ 的值取为交通流量 Volterra 级数模型之中的交通流量混沌时间序列, 则它们在功能、结构以及求解方法三个方面存在本质的相似性, 具体如下:

1) 分析它们的功能, ANN 神经网络模型和交通流量混沌时间序列 Volterra 级数模型都可以利用历史和实测交通流量, 来模拟和预测交通流量的过程. 通过分析交通流量时间序列的因果关系和有限记忆性能来确定交通流量 Volterra 模型的截断阶数和项数, 在此基础上, 利用神经网络辨识方法计算获得 Volterra 核函数, 或者通过线形空间投影、最小二乘支持向量机、Volterra 滤波器以及分块最小均方滤波器等方法来求解 Volterra 级数或 Volterra 核函数, 从而反映出交通流量时间序列具有一定的混沌非线性特征.

2) 分析它们的结构, ANN 神经网络模型和交通流量 Volterra 模型都满足同构性. 具体来说, 就是交通流量混沌时间序列 Volterra 模型中, 混沌时间序列对过去交通流量的存储记忆长度等价于 ANN 神经网络模型中输入层的神经元个数, 即混沌相空间重构的最小嵌入维数.

3) 分析它们的求解方法, ANN 神经网络模型则是以训练神经网络权值的手段来实现对期望输出的不断逼近, 而交通流量 Volterra 模型是通过用正交多项式作数值逼近的方法来求其近似解, 其中, Meixner 函数系和网络权值两者在模型逼近的功能上具有相同的作用.

分析比较 ANN 神经网络模型与交通流量混沌时间序列 Volterra 模型的等价性后, 本文在交通流量混沌时间序列 Volterra 泛函级数结构模型的基础上提出了交通流量混沌时间序列 Volterra 神经网络模型 (Volterra neural network traffic flow model, VNNTF), 其模型结构如图 2 所示.

在图 2 中, 输入层的输入向量 $\mathbf{X}(t) = \bar{\mathbf{x}}(t) = (\mathbf{x}(t), \mathbf{x}(t+\tau), \dots, \mathbf{x}(t+(m-1)\tau))^T$ ($t = 1, 2, \dots$) 为交通流量混沌时间序列重构相空间向量, g_s ($s = 1, 2, \dots, N$) 为隐层激活函数, $w_{i,j}$ ($i = 1, 2, \dots; j = 1, 2, \dots$) 和 r_n 分别为交通流量混沌时间序列 Volterra 神经网络隐层和输出层的权值参数; $V_s(k)$ 为交通流量输入信号的卷积, 其表达式为

$$V_N(t) = \sum_{i=0}^m w_{N,i} x(t+(i-1)\tau) \quad (8)$$

进一步, 可以得到交通流量混沌时间序列 Volterra 神经网络的表达式如下:

$$\hat{y}(t) = f(\mathbf{X}(t)) = f(\bar{\mathbf{x}}(t)) = \sum_{s=1}^N r_s g_s(V_N(t)) = \sum_{s=1}^N r_s g_s \left(\sum_{i=1}^m w_{s,i} x(t+(i-1)\tau) \right) \quad (9)$$

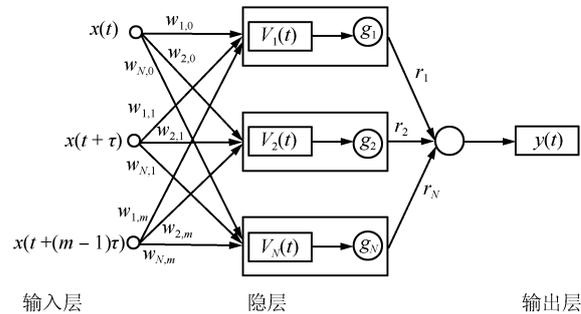


图 2 交通流量混沌时间序列 Volterra 神经网络模型
Fig. 2 The chaotic time series Volterra neural network traffic flow model

3 交通流量混沌时间序列 Volterra 神经网络模型 (VNNTF) 快速学习算法

文中所采样的交通流量数据来自于重庆市某路段双车道 28 小时零 5 分钟的每间隔 5 分钟 (包括微型车、轻型车、微面包车、小客车、中型车、大型车、全挂车以及不定型车等车辆) 的交通流量时间序列, 得到的交通流量时间序列长度为 $n = 337$. 在这里, 模型采用输入、输出和单隐层的 3 层交通流量 Volterra 神经网络结构. 通过混沌理论和相空间重构理论可以计算得到交通流量混沌时间序列的嵌入维数 $m = 4$, 将其作为输入层神经元个数; 而隐层的神经元个数采用交通流量向量序列的灰色关联分析方法可以确定为 9; 输出层为单输出层, 其神经元个数为 1. 这样, 就可以建立得到一个 4-9-1 结构模型的交通流量混沌时间序列 Volterra 神经网络模型. 通常情况下, 隐层的激活函数可以选取高斯函数、分段函数等, 本文所采用的是多项式激活函数 $g_s = a_{0,s} + a_{1,s}x + a_{2,s}x^2 + \dots + a_{i,s}x^i + \dots$, 其中 $a_{i,s} \in \mathbf{R}$ 为多项式系数. 通过交通流量混沌时间序列 Volterra 神经网络模型的网络学习和训练来减小目标误差 E , 从而来获得最优的神经网络权值参数 $w_{s,j}$ 和 r_s (在这里 $s = 1, 2, \dots, N; j = 1, 2, \dots, m$), 最后, 比较多项式系数计算出 $h_j(l_1, l_2, \dots, l_j)$ ($j = 1, 2, \dots, m$).

算法流程图 VNNTF 模型学习算法的流程图如图 3 所示.

下面是 VNNTF 神经网络模型快速学习算法, 其算法步骤具体如下:

算法 1. VNNTF 神经网络模型快速学习算法

步骤 1. 根据图 2 的交通流量混沌时间序列 Volterra 神经网络模型, 建立一个 4-9-1 形式的 VNNTF 神经网络结构. 输入层的交通流量信号为 $(\mathbf{x}(t), \mathbf{x}(t+\tau), \dots, \mathbf{x}(t+(m-1)\tau))^T$ ($t = 1, 2, \dots$), 输出层的输出为 $\hat{y}(t)$, 隐层的网络权值系数矩阵为 $w = (w_{s,l_j})_{N \times m} = (w_{s,i})_{N \times m}$ ($s = 1, 2, \dots, 9; i, j = 1, 2, \dots, 4$) 和参数 r_s ($s = 1, 2, \dots, 9$).

步骤 2. 对 VNNTF 网络模型的参数 $w = (w_{s,l_j})_{N \times m}$

和 r_s ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$) 进行初始化. 参数矩阵 $w = (w_{s,l_j})_{N \times m}$ 的初始化是在 0 与 1 之间产生随机数 $N \times m$ 矩阵, 而对于隐层到输出层的权值参数 $r_s, s = 1, 2, \dots, 9$ 的初始化是在 0 与 1 之间的随机数.

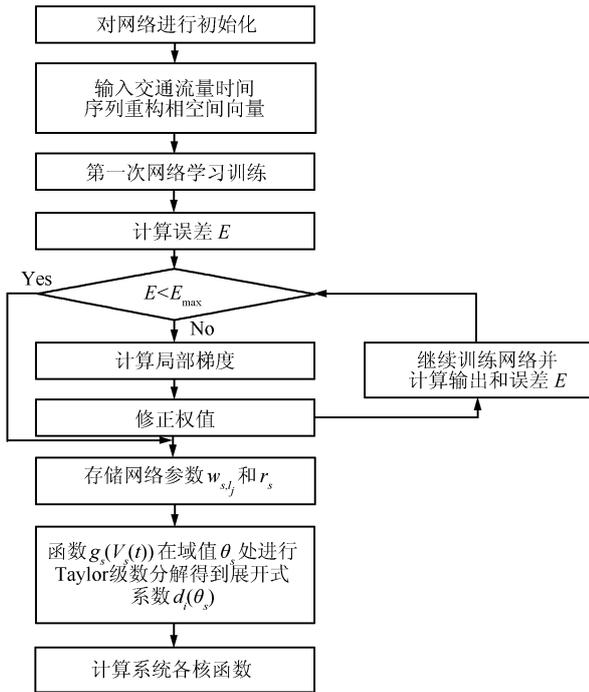


图 3 VNNTF 快速学习算法流程图

Fig. 3 The fast learning algorithm flow chart of VNNTF

步骤 3. 对交通流量混沌时间序列进行数据预处理, 以及对混沌相空间重构好的 VNNTF 网络的输入信号作数据归一化处理. 用混沌相空间重构理论得到延迟时间为 $\tau = 3$, 最小嵌入维数为 $m = 4.337$ 个交通流量数据通过重构可以得到 $N - 1 - (m - 1)\tau = 327$ 个重构相空间向量, 将前 250 个向量作为 VNNTF 网络的输入, 其表达式为 $(\mathbf{x}(t), \mathbf{x}(t + \tau), \dots, \mathbf{x}(t + (m - 1)\tau))^T$, 其中, $t = 1, 2, \dots, 250, m = 4, \tau = 3$.

接着对该 250 个重构相空间向量作数据归一化处理, 其过程为 $[x(t) - \text{mean}(x(t))]/[\max(x(t)) - \min(x(t))], t = 1, 2, \dots, 250$, 使得数值取值落在 -0.5 到 0.5 的区间内部.

步骤 4. 利用步骤 2 和步骤 3 中获得的数据对 VNNTF 神经网络, 计算交通流量预测值, 其计算公式为

$$\hat{y}(t) = \sum_{s=1}^N \sum_{i=1}^{\infty} r_s a_{i,s} \left(\sum_{i=0}^m w_{s,i} x(t + (i - 1)\tau) \right)^i \quad (10)$$

进行第一次网络训练学习, 在这里, 激活函数选取为多项式 g_s , 其中, $a_{i,s} \in \mathbf{R}$ 是多项式的系数, 则可以得到交通流量预测值 $\hat{y}(t)$.

步骤 5. 根据真实值和预测值之间的差的平方和计算目标误差函数 E , 按照以下公式

$$E = \frac{1}{2} \sum_{i=1}^{250} (y(t) - \hat{y}(t))^2 \quad (11)$$

在这里最大误差设为 $E_{\max} = 0.035$, 比较 E 和 E_{\max} , 若 $E < E_{\max} = 0.035$, 则停止计算, 存储网络训练参数

$w = (w_{s,l_j})_{N \times m}$ 和 r_s ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$), 进一步结合多项式系数 $a_{i,s}$ ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$), 可以计算并输出系统各核函数 $h_j(l_1, l_2, \dots, l_j)$ ($j = 1, 2, \dots, 4$); 否则, 进入步骤 6 继续.

步骤 6. 计算 VNNTF 神经网络模型的局部梯度. 具体按照式 $\delta_j(t) = (y(t) - \hat{y}(t))g'_s(V_j(t))$ (这里 j 是输出层) 和公式

$$\delta_j(t) = -\frac{\partial E(t)}{\partial y(t)} g'_s(V_j(t)) \quad (12)$$

(其中, j 是隐层) 计算出局部梯度.

步骤 7. 通过引入动量项的方法来调整交通流量混沌时间序 Volterra 神经网络的权值. 其权值参数修正计算公式为

$$\Delta w_{j,i}(t) = \alpha \Delta w_{j,i}(t - 1) + \eta \delta_j(t) y(t), \quad 0 < \alpha < 1 \quad (13)$$

其中, j 为隐层或输出层, η 为学习步长, $\alpha \Delta w_{j,i}(t - 1)$ 为引入的动量项, 其中 $\delta_j(t)$ 取值按照步骤 6 中的方法进行计算.

步骤 8. 计算修正 VNNTF 神经网络权值, 利用修正好的网络权值, 再次训练神经网络, 并计算出网络的输出 $\hat{y}(t)$ 和目标误差 E , 不断进行下去, 直至满足 $E < E_{\max} < 0.035$, 转入下一步.

步骤 9. 计算存储 VNNTF 网络的每次训练的权值矩阵 $w = (w_{s,l_j})_{N \times m}$ 和 r_s ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$), 并且将 $g_s(V_s(t))$ 在域值 θ_s 处进行 Taylor 展开, 可以得到 Taylor 展开式的系数 $d_i(\theta_s)$, 如果 $g_s(V_s(t))$ 是多项式, 那么 $d_i(\theta_s) = a_{i,s}$ ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$).

步骤 10. 最后, 将步骤 9 中网络参数和展开式的系数 $d_i(\theta_s)$ 的结果, 代入式 $h_j(l_1, l_2, \dots, l_j) = \sum_{s=1}^N r_s d_i(\theta_s) w_{s,l_1} w_{s,l_2} \dots w_{s,l_j}$ ($s = 1, 2, \dots, 9, i = 1, 2, \dots, 4$), 可以计算并输出系统的各核函数.

4 实验结果与分析

预测通常分为单步预测和多步预测, 其中多步预测是衡量预测模型预测性能的一个重要指标, 在应用中具有重要的价值. 多步预测通常用在提前预警、交通诱导、宏观决策、多步控制等类型的预测问题, 例如移动通信话务量多步预测, 可为电信运营商提供预警信息, 提前处理超忙区域; 股票市场由于受到政治、经济、市场人气和公司运营状况等多方面因素的影响, 使股价走势呈现不规律性, 股票价格指数多步预测, 可以帮助决策部门掌握经济运行的动向, 制定较好的宏观调控政策; 交通诱导系统则需要相对较长时间的预测信息, 交通流量多步预测能够使相关部门掌握道路交通状态的发展趋势, 提前介入, 采取相应措施, 预防交通拥堵的发生. 交通流量混沌时间序列多步预测指的是, 假设样本数量为 N , 在无法得到新的交通流量混沌时间序列采样或者只利用该 N 个样本, 在单步预测第 $N + 1$ 个值之外, 也可以预测第 $N + 2, N + 3, \dots, N + T$ ($T > 0$) 个值, 即通过已知的样本集可以外推进行 T 步预测. 实验中, 进行交通流量 VNNTF 神经网络的多步预测研究, 并且把预测的结果与 Volterra 滤波器和 BP 神经网络多步预测的结果进行比较, 进一步分析产生不同预测结果的因素所在.

在多步预测 VNNTF 神经网络训练过程中, 选取 2 步、3 步和 4 步预测, 从交通流量混沌时间序列的重构相空间向量的 327 个中, 选取前 250 个向量作训练, 其训练目标是从第 t' 个交通流量信号到第 $t' + 249$ 个交通流量信号, 这里 $t' = 12, 13, 14$, 神经网络训练好以后, 为了与实测交通流量

信号作分析和比较, T ($T = 2, 3, 4$) 步预测交通流量信号取值的是第 $260 + T$ ($T = 2, 3, 4$) 到采样结束的第 337 个交通流量信号, 即预测的步数每增加一个, 那么其预测数就会减少一个. 若不与交通流量实测信号作预测比较, 则没有这个限制.

分别计算图 4、图 6 和 8 的误差方均根, 并与 BP 神经网络、Volterra 滤波的误差方均根进行比较, 比较结果如表 1 所示. 从表 1 中可知, 随着多步预测步数的不断增大, 对于每个相同的预测步数, 应用 VNNTF 模型快速学习算法的 VNNTF 神经网络预测交通流量混沌时间序列的预测值的方均根, 明显小于 BP 神经网络和 Volterra 滤波的预测值的方均根.

表 1 归一化后的方均根比较表

Table 1 Normalization of RMSE comparison

预测步数	BP 网络预测	Volterra 滤波	VNNTF 网络
1 步	0.7014	0.3567	0.1368
2 步	0.8074	0.3941	0.1507
3 步	0.8653	0.4225	0.2322
4 步	0.9799	0.4782	0.2417

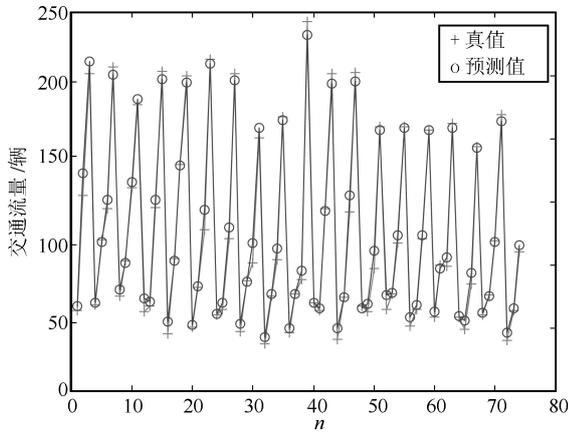


图 4 VNNTF 网络 2 步预测结果与真实结果比较曲线图

Fig. 4 Comparison of the 2-step forecast result and real result by VNNTF network

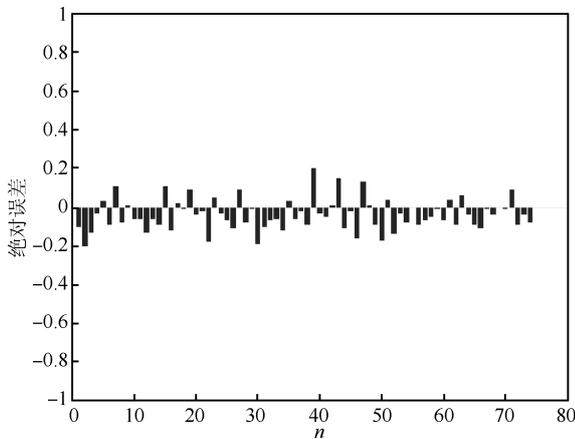


图 5 VNNTF 网络 2 步预测的绝对误差柱状图

Fig. 5 Absolute error histogram of the 2-step forecast by VNNTF network

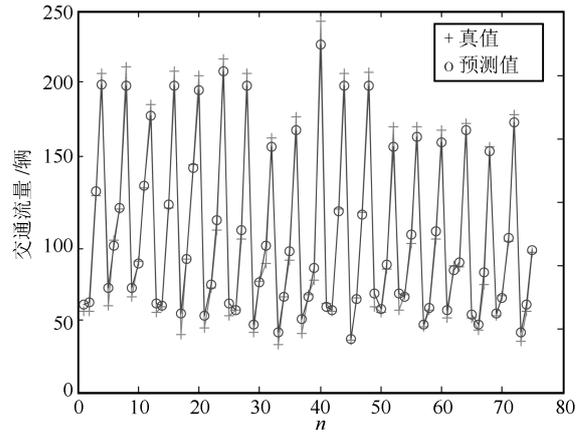


图 6 VNNTF 网络 3 步预测结果与真实结果比较曲线图

Fig. 6 Comparison of the 3-step forecast result and real result by VNNTF network

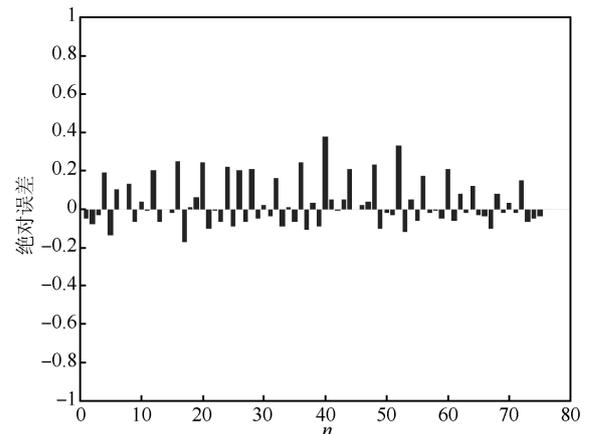


图 7 VNNTF 网络 3 步预测的绝对误差柱状图

Fig. 7 Absolute error histogram of the 3-step forecast by VNNTF network

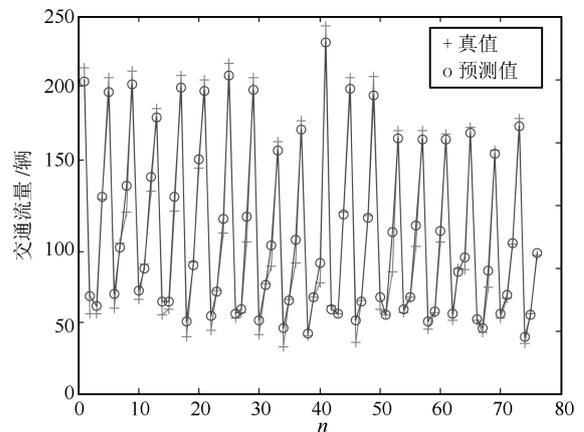


图 8 VNNTF 网络 4 步预测结果与真实结果比较曲线图

Fig. 8 Comparison of the 4-step forecast result and real result by VNNTF network

图 4、图 6 和图 8 分别对应的是 VNNTF 神经网络的 2 步、3 步和 4 步预测的交通流量预测结果与真实结果的比较曲线图, 而图 5、图 7 和图 9 分别对应的是 2 步、3 步、4 步

的真实值和预测值的误差柱状图. 从这些误差柱状图可以看出交通流量混沌时间序列 VNNTF 网络模型的结果要比 3 步预测的结果好; 3 步预测的结果要比 4 步预测的结果好. 因此, 从整体上分析, 多步预测随着预测步长的不断增加, 其预测性能将不断变差.

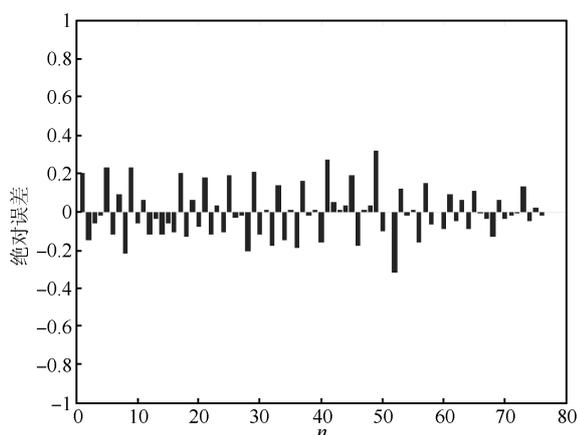


图9 VNNTF 网络 4 步预测的绝对误差柱状图

Fig. 9 Absolute error histogram of the 4-step forecast by VNNTF network

分析比较 BP 网络、Volterra 预测滤波器和 VNNTF 网络模型对交通流量的预测机理和性能: 1) 从模型的建立上分析, BP 网络在模型的选择过程中, 缺乏统计机理, 其变量的选择也缺少合适的选择准则, 容易造成多余的不相关变量和忽略重要变量, 将预测的精度和准确度产生重要影响; Volterra 滤波器模型的建模思想是通过逐点拟合训练交通流量混沌吸引子轨道, 实现对其非线性特征的联想记忆, 在此过程中, Volterra 滤波器实现复杂性的选择是将 Volterra 滤波器线性化, 采用线性滤波器的乘积耦合方式来近似实现, 系统的输出是滤波器系数的非线性函数; 而 VNNIF 神经网络模型的思想是通过 Volterra 级数离散化模型结合交通流量混沌、因果及记忆功能特性确定 Volterra 模型的截断阶数和项数, 实现 Volterra 级数精确建模, 最后通过比较 ANN 神经网络模型与交通流量混沌时间序列 Volterra 模型的等价性, 计算核函数并对交通流量进行预测. 2) 从运行速度和计算量上分析, BP 网络是静态网络, 根据初始样本的训练对未来进行预测, 而且 BP 网络很容易陷入局部极小点, 因而 BP 网络的预测效果最差, 训练时间最长; Volterra 滤波器采用少参数的二阶 Volterra 滤波器一种乘积耦合近似实现, Volterra 滤波器预测法利用自适应算法调整参数, 因而该法能够根据新的信息反馈做出准确的预测, 训练时间短; VNNIF 神经网络模型根据交通流量本身的特性, 确定 Volterra 模型的截断阶数和项数, 保证了 Volterra 级数精确建模, 采用前馈 ANN 神经网络训练学习, 其计算量比少参数二阶 Volterra 滤波器大, 但由于有精确的结构, 计算量比 BP 网络要小; 在预测结果上, VNNIF 神经网络模型比 Volterra 滤波器和 BP 网络的预测精度有显著的提高.

通过比较和分析交通流量混沌时间序列 VNNTF 网络模型的多步预测的结果, 从总体上可看出 2 步、3 步和 4 步对交通流量的预测性能比 Volterra 滤波器预测和 BP 神经网络预测的效果都要好, 这是因为 VNNTF 网络结合了前馈 ANN 神经网络和 Volterra 级数的优点, 同时克服了 ANN 神经网络建模的盲目性和 Volterra 滤波器求解核函数的困难.

实际上, 在实验中还发现 VNNTF 网络对交通流量混沌时间序列的预测结果比小波神经网络的预测效果也要好, 这说明建立一个好的交通流量预测模型比选择一种好的预测算法更加重要, 从这点上来说, 交通流量预测模型的选取是关系到预测质量好坏的最重要的因素.

5 结论

本文给出了交通流量 Volterra 泛函级数模型截断阶数和项数的方法, 设计了 VNNTF 网络模型, 提出了一种基于混沌理论的交通流量 VNNTF 神经网络快速学习算法, 并对交通流量混沌时间序列进行了多步预测. 该方法结合了 Volterra 级数精确建模和 ANN 神经网络学习训练的优点, 并且在模型选取、算法设计两个方面, 都考虑了交通流量的混沌特性, 具有一定的理论价值. 实验仿真表明, 该方法可以减少交通流量预测值和真实值的方均根, 提高交通流量预测的精度, 对混沌时间序列的预测可以取得很好的预测效果.

References

- Xiao Z L, Jing X J, Cheng L. Parameterized convergence bounds for Volterra series expansion of NARX models. *IEEE Transactions on Signal Processing*, 2013, **61**(20): 5026–5038
- Zhu Xiong-Yong, Zhou Jie, Tan Hong-Zhou. Method for eliminating LCD motion de-blurring model's pole. *Acta Automatica Sinica*, 2012, **38**(5): 759–768 (朱雄泳, 周杰, 谭洪舟. 一种消除 LCD 运动图像去模糊模型极点的方法. *自动化学报*, 2012, **38**(5): 759–768)
- Asyali M, Alc M. Obtaining Volterra kernels from neural networks. In: *Proceedings of World Congress on Medical Physics and Biomedical Engineering 2006, IFMBE Proceedings*. Berlin: Springer Berlin Heidelberg, 2007. 11–15
- Silveira D D, Gilabert P L, dos Santos A B, Gadringer M. Analysis of variations of volterra series models for RF power amplifiers. *IEEE Microwave and Wireless Components Letters*, 2013, **23**(8): 442–444
- Ghasemi M, Tavassoli K M, Babolian E. Numerical solutions of the nonlinear Volterra-Fredholm integral equations by using homotopy perturbation method. *Applied Mathematics and Computation*, 2007, **188**(1): 446–449
- Meng X Z, Chen L S. Permanence and global stability in an impulsive Lotka-Volterra n -species competitive system with both discrete delays and continuous delays. *International Journal of Biomathematics*, 2008, **1**(2): 179–196
- Despotovic V, Goertz N, Peric Z. Nonlinear long-term prediction of speech based on truncated Volterra series. *IEEE Transactions on Audio, Speech, and Language Processing*, 2012, **20**(3): 1069–1073
- Chen F D. Permanence and global attractivity of a discrete multispecies Lotka-Volterra competition predator-prey systems. *Applied Mathematics and Computation*, 2006, **182**(1): 3–12
- Kobayakawa S, Yokoi H. Evaluation of prediction capability of Non-recursion type 2nd-order Volterra neuron network for electrocardiogram. In: *Proceedings of the 15th International Conference on Neuro-Information Processing of the Asia Pacific Neural Network Assembly, Lecture Notes in Computer Science*. Berlin, Heidelberg: Springer, 2009, **5507**: 679–686
- Kang Ling, Wang Cheng, Jiang Tie-Bing. Hydrologic model of Volterra neural network and its application. *Journal of Hydroelectric Engineering*, 2006, **25**(5): 22–26 (康玲, 王乘, 姜铁兵. Volterra 神经网络水文模型及应用研究. *水力发电学报*, 2006, **25**(5): 22–26)

- 11 Rubiolo M, Stegmayer G, Milone D. Compressing arrays of classifiers using Volterra-neural network: application to face recognition. *Neural Computing & Applications*, 2013, **23**(6): 1687–1701
- 12 Yu J L, Yi Z, Zhou J L. Fcontinuous attractors of Lotka-Volterra recurrent neural networks with infinite neurons. *IEEE Transactions on Neural Networks*, 2010, **21**(10): 1690–1695
- 13 Jia Li, Yang Ai-Hua, Qiu Ming-Sen. Research on multi-signal based neuro-fuzzy Hammerstein-Wiener model. *Acta Automatica Sinica*, 2013, **39**(5): 690–696
(贾立, 杨爱华, 邱铭森. 基于多信号源的神经模糊 Hammerstein-Wiener 模型研究. *自动化学报*, 2013, **39**(5): 690–696)
- 14 Si Wei, Duan Zhe-Min, Wang Hai-Tao. Novel method based on projection of vectors in linear space to identify Volterra kernels of arbitrary orders. *Application Research of Computers*, 2008, **25**(11): 3340–3342
(司伟, 段哲民, 王海涛. 基于线性空间投影的计算 Volterra 级数高阶核的方法. *计算机应用研究*, 2008, **25**(11): 3340–3342)
- 15 Li Peng-Hua, Chai Yi, Xiong Qing-Yu. Quantum gate Elman neural network and its quantized extended gradient back-propagation training algorithm. *Acta Automatica Sinica*, 2013, **39**(9): 1511–1522
(李鹏华, 柴毅, 熊庆宇. 量子门 Elman 神经网络及其梯度扩展的量子反向传播学习算法. *自动化学报*, 2013, **39**(9): 1511–1522)
- 16 Zhao H Q, Zeng X P, He Z Y. Low-complexity nonlinear adaptive filter based on a pipelined bilinear recurrent neural network. *IEEE Transactions on Neural Networks*, 2011, **22**(9): 1494–1507
- 17 Wu Yu-Xiang, Wang Cong. Deterministic learning based adaptive network control of robot in task space. *Acta Automatica Sinica*, 2013, **39**(9): 806–815
(吴玉香, 王聪. 基于确定学习的机器人任务空间自适应神经网络控制. *自动化学报*, 2013, **39**(9): 806–815)
- 18 Yakubov Y A. On nonlinear Volterra equations of convolution type. *Differential Equations*, 2009, **45**(9): 1326–1336
- 19 Murakami S, Ngoc P H A. On stability and robust stability of positive linear Volterra equations in Banach lattices. *Central European Journal of Mathematics*, 2010, **8**(5): 966–984
- 20 Bibik Y V. The second Hamiltonian structure for a special case of the Lotka-Volterra equations. *Computational Mathematics and Mathematical Physics*, 2007, **47**(8): 1285–1294
- 21 Yin L S, Huang X Y, Yang Z Y, Xiang C C. Prediction for chaotic time series based on discrete Volterra neural networks. In: Proceedings of the 3rd International Symposium on Neural Networks, Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2006, **3972**: 759–764

殷礼胜 博士, 合肥工业大学电气与自动化工程学院副教授. 2007 年获得重庆大学控制科学与工程专业博士学位. 主要研究方向为混沌理论, 交通流, 神经网络, 现代智能算法. 本文通信作者.

E-mail: yls20000@163.com

(YIN Li-Sheng Ph.D., associate professor at the School of Electrical Engineering and Automation, Hefei University of Technology. He received his Ph.D. degree in control science and engineering from Chongqing University in 2007. His research interest covers modern intelligent algorithm, chaos theory, neural network theory, and fuzzy theory. Corresponding author of this paper.)

何怡刚 博士, 合肥工业大学电气与自动化工程学院教授. 主要研究方向为复杂电网状态监测与健康诊断, 电力市场及其技术支持系统, 极大规模集成电路设计测试与诊断, 自动(射频)识别技术, 复杂电磁分析与建模, 虚拟仪器与智能信号处理. E-mail: hyghnu@yahoo.com.cn

(HE Yi-Gang Ph.D., professor at the School of Electrical Engineering and Automation, Hefei University of Technology. His research interest covers complex grid condition monitoring and health management, power market and its technical support system, ultra large-scale integrated circuit design tests and diagnostics, automatic (RF) identification technology, complex electromagnetic analysis and construction mode, virtual instruments and intelligent signal processing.)

董学平 博士, 合肥工业大学电气与自动化工程学院副教授. 2008 年获得南京理工大学控制科学与工程专业博士学位. 主要研究方向为分布参数系统, 切换系统和过程控制. E-mail: hfdxp@126.com

(DONG Xue-Ping Ph.D., associate professor at the School of Electrical Engineering and Automation, Hefei University of Technology. He received his Ph.D. degree in control science and engineering from Nanjing University of Science and Technology in 2008. His research interest covers distributed parameter systems, switched systems, and process control.)

鲁照权 博士, 合肥工业大学教授. 主要研究方向为大时滞不确定过程及控制, 复杂系统及控制, 智能控制, 无线通讯网络与自动化系统, 汽车电子技术研究与开发, 节能控制系统研究与开发.

E-mail: luzhquan@126.com

(LU Zhao-Quan Ph.D., professor at the School of Electrical Engineering and Automation, Hefei University of Technology. His research interest covers large time delay uncertain process and control, complex systems and controls, intelligent control, wireless communication network and automation systems, automotive electronics technology research and development, energy-saving control system research and development.)