

doi:10.3969/j.issn.1673-9833.2013.06.014

基于 ESN 和 Elman 神经网络的交通流预测对比研究

罗 轶

(湖南师范大学 物理与信息科学学院, 湖南 长沙 410081)

摘 要: 实时准确的短时交通流预测是实现智能交通系统中交通控制和交通诱导的关键技术之一。由于短时交通流数据的复杂性, 首先采用饱和关联维数法和 Cao 氏法对交通流时间序列的嵌入维数和延迟时间进行计算, 并采用 Wolf 方法计算相空间重构后的交通流时间序列的最大 Lyapunov 指数。结果表明, 交通流时间序列具有混沌特性, 可预测性较好。随后, 分别采用基于 ESN 和 Elman 神经网络的预测方法对交通流时间序列进行预测, 结果表明, 两者在预测精度相当的情况下, 前者的训练速度较后者有了极大的提高。

关键词: 交通信息工程及控制; 相空间重构; 回声状态网络; Elman 神经网络; 交通流预测

中图分类号: U495

文献标志码: A

文章编号: 1673-9833(2013)06-0067-06

Comparative Study on Traffic Flow Prediction Based on ESN and Elman Neural Networks

Luo Yi

(Institute of Physics and Information Science, Hunan Normal University, Changsha 410081, China)

Abstract: The real-time and precise short-term traffic flow prediction is the key factor for the realizing of traffic control and traffic guidance in the intelligent traffic system. As the complexity of short-term traffic flow data, the saturated correlation dimension method and Cao's method are adopted to calculate the embedding dimension and delay time of traffic flow time series, and the Wolf method is applied to calculate the largest Lyapunov exponent of the reconstructed traffic flow time series. The result shows that the traffic flow series is a chaotic sequence with better predictability. Then the prediction methods based on ESN and Elman neural networks are applied to predict traffic flow time series respectively, it indicates that the former has quicker prediction speed on the condition of the same prediction accuracy.

Keywords: traffic information engineering and control; phase space reconstruction; echo state network; Elman neural networks; traffic flow prediction

随着我国公路交通事业的快速发展, 城市车辆保有量逐年增加, 近十几年来, 交通拥堵、环境污染、能源短缺和道路安全交通事故多发等已成为制约我国经济快速发展的社会性问题。当前我国正将智能交通技术作为解决交通问题的有效方法之一而

加以大力推广和应用, 其中交通控制和诱导系统是智能交通系统的关键, 而交通流预测则是新一代交通控制和诱导系统依赖的核心技术。目前, 国内外已有不少学者将神经网络引入交通流预测研究中, 并取得了一些成果。随着 2004 年 H. Jaeger 等^[1]

收稿日期: 2013-10-23

基金项目: 湖南省教育厅科学研究基金资助项目(11C0816)

作者简介: 罗 轶(1980-), 男, 广西陆川人, 湖南师范大学讲师, 中南大学博士生, 主要从事移动通信与交通信息处理方面的研究, E-mail: km_luoyi@sina.com

在《Science》期刊中提出将回声状态网络 (echo state network, ESN) 能用于混沌序列的高精度预测后, ESN 的应用研究便在学术界如火如荼地展开。文献[2-3] 对基于 BP (back propagation) 和 Elman 神经网络的交通流预测方法进行了研究, 结果表明, 采用 Elman 神经网络对具动态特性的交通流时间序列进行预测, 能获得比采用 BP 神经网络更好的预测效果。文献[4-5] 对 ESN 神经网络的应用范围进行了研究, 结果表明, ESN 网络由于独特的网络结构和强大的短时记忆特性, 特别适用于混沌时间序列的预测, 并在训练效率和结果稳定性方面具有突出优点。本文将 ESN 网络引入对短时交通流时间序列预测中, 并与目前交通流预测中性能较好的 Elman 神经网络进行对比分析, 以期对 ESN 网络在交通流预测中的应用进行探讨。

1 ESN 和 Elman 神经网络原理

回声状态网络是一种由输入层、隐含层和输出层 3 部分组成的新型递归神经网络。隐含层由数目相对较多、连接关系随机产生且相互之间稀疏连接的神经元构成, 并形成巨大的动态储备池 (dynamic reservoir, DR), 其网络结构如图 1 所示^[4]。




图1 回声状态网络结构

Fig. 1 Echo state networks structure

设网络具有 A 个输入单元、 B 个储备池状态连接神经元、 C 个输出单元, 输入向量 $\mathbf{u}(n)$ 、状态连接向量 $\mathbf{x}(n)$ 和输出向量 $\mathbf{y}(n)$ 表示如下:

$$\mathbf{u}(n) = [u_1(n), u_2(n), \dots, u_A(n)]^T, \quad (1)$$

$$\mathbf{x}(n) = [x_1(n), x_2(n), \dots, x_B(n)]^T, \quad (2)$$

$$\mathbf{y}(n) = [y_1(n), y_2(n), \dots, y_C(n)]^T. \quad (3)$$

在时间点 n , 回声状态网络的状态更新方程和输出方程表示如下:

$$\mathbf{x}(n+1) = f_R(\mathbf{W}\mathbf{x}(n) + \mathbf{W}^{\text{in}}\mathbf{u}(n) + \mathbf{W}^{\text{back}}\mathbf{y}(n)), \quad (4)$$

$$\mathbf{y}(n+1) = f_O(\mathbf{W}^{\text{out}}\mathbf{x}(n+1)). \quad (5)$$

其中输入权值矩阵 \mathbf{W}^{in} 为 $A \times B$ 维, 储备池内部神

经元连接权值矩阵 \mathbf{W} 为 $B \times B$ 维, 输出权值矩阵 \mathbf{W}^{out} 为 $B \times C$ 维, 输出神经元与储备池的反馈权值矩阵 \mathbf{W}^{back} 为 $C \times B$ 维; $f_R(\cdot)$ 是储备池神经元激活函数, 一般选用非线性函数, 如 Sigmoid 函数; $f_O(\cdot)$ 是输出激活函数, 一般选用线性函数, 如恒等函数。由于在对混沌时间序列预测时采用无输出反馈的基本模式, 所以 $\mathbf{W}^{\text{back}} = \mathbf{0}$ 。输出权值矩阵 \mathbf{W}^{out} 的训练步骤如下^[4-6]。

1) 初始化回声状态网络。权值矩阵 \mathbf{W}^{in} 和 \mathbf{W} 随机产生, 两个权值矩阵的元素均初始化为服从 $[0, 1]$ 均匀分布的随机数, 一旦产生就不再改变, 状态向量 $\mathbf{x}(0)$ 设置为 $\mathbf{0}$;

2) 更新回声状态网络储备池状态向量。根据式 (4), 由给定的输入向量 $\mathbf{u}(n)$ 和状态连接向量 $\mathbf{x}(n)$ 计算新的储备池状态向量 $\mathbf{x}(n+1)$;

3) 计算输出权值矩阵 \mathbf{W}^{out} 。首先, 选定时间点 $n = M_0$ 之后的所有状态连接向量和期望输出向量对权值矩阵 \mathbf{W}^{out} 进行训练, 即取:

$$n = M_0, M_0 + 1, \dots, M,$$

$$\mathbf{X} = [\mathbf{x}(M_0), \mathbf{x}(M_0 + 1), \dots, \mathbf{x}(M)]^T,$$

$$\mathbf{Y} = [\mathbf{y}(M_0), \mathbf{y}(M_0 + 1), \dots, \mathbf{y}(M)]^T,$$

随后采用基本的线性回归算法求出 \mathbf{W}^{out} :

$$(\mathbf{W}^{\text{out}})^T = \mathbf{X}^{-1}\mathbf{Y}. \quad (6)$$

完成输出权值矩阵 \mathbf{W}^{out} 训练后, 将时间点 $n = M$ 之后的所有输入向量 $\mathbf{u}(n), n = M + 1, \dots, N$ 作为测试输入向量, 代入式 (5), 得到预测输出向量 $\hat{\mathbf{y}}(n)$ 。

回声状态网络的性能主要受储备池特性的影响, 储备池特性主要由以下 4 个参数决定^[6]: 1) 储备池规模 B 。储备池中神经元数目是储备池的最重要参数。 B 选择过小, 网络对期望输出信号拟合差, 导致欠拟合; B 选择过大, 网络复杂, 对输入向量过于敏感, 产生过拟合。2) 储备池谱半径 R 。连接矩阵 \mathbf{W} 最大特征值的绝对值称为储备池谱半径。 R 决定了网络的稳定性, 在对混沌时间序列进行预测时, 一般取 $0 < R < 1$ 。3) 输入缩放系数 F_{in} 。输入向量在进入储备池前缩放的比例称为输入缩放系数, 其决定了储备池的非线性程度。4) 稀疏度 D 。储备池内部神经元连接的活跃程度称为稀疏度, D 一般取 10% 以内。

ESN 网络从结构来看与 Elman 神经网络有着极其相似的地方, 但是两者核心部分存在本质上的不同。ESN 网络以其储备池具有的丰富储备容量、稀疏连接方式、简单权值训练和短时记忆特性巧妙地解决了传统神经网络 (如 BP, RBF 和 Elman 等) 运行效率低、训练时间长的缺点, 非常适合具有混沌特性的

短时交通流时间序列预测。

Elman神经网络又称Elman反馈神经网络,是一种具有局部记忆单元和局部反馈连接的前向型神经网络。网络结构包括输入层、隐含层和输出层3层,各层的连接类似于前馈网络,但Elman神经网络的隐含层与BP神经网络相比多出了一个关联层也称联系单元层部分。每一个隐含层节点对应连接一个关联层节点,关联层将前一时间点的隐含层状态以及神经网络当前时间点的输入向量接收后一起反馈给隐含层^[2-3,11]。由于Elman神经网络应用较广,在此就不对其作过多的介绍。

2 交通流时间序列的相空间重构

对于交通流时间序列这种一维的标量时间序列,其时间序列图根本无法完全反映出交通流复杂的动力学特性,所以对交通流时间序列进行预测首先要完成的是相空间重构。F. Takens等^[7]在拓扑学理论的基础上提出了基于延迟坐标的相空间重构法,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。依据Takens定理,对于交通流时间序列 $q(n)$,采样点 $n=1, 2, \dots, N$,采用基于延迟坐标的相空间重构法对 $q(n)$ 进行重构可得:

$$\mathbf{Q}(n) = [q(n), q(n-\tau), q(n-2\tau), \dots, q(n-(m-1)\tau)]^T, \quad (7)$$

式中: $\mathbf{Q}(n)$ 为相空间重构后的多维交通流时间序列; $n=(m-1)\tau+1, \dots, N$; τ 为延迟时间; m 为嵌入维数。本文将对延迟时间 τ 、嵌入维数 m 和最大Lyapunov指数的计算方法进行探讨。

2.1 延迟时间 τ 的计算

延迟时间 τ 对于反映时间序列的动力学特性非常重要, τ 选择过小,相空间矢量中的任意两个分量因相空间轨迹受到挤压导致数值上非常接近,以至难以相互区分; τ 选择过大,将使得混沌吸引子的轨迹在2个方向上的投影毫无相关性可言。本文采用互信息量法来计算交通流时间序列的延迟时间,其步骤如下^[8-10]。

1) 对于离散时间序列 $U = \{u_1, u_2, \dots, u_m\}$ 计算其延迟时间为 τ 的离散时间序列 $V = \{v_1, v_2, \dots, v_n\}$,其中 $m=n$, $u_i = v_i + \tau$ 。

2) 计算序列 U 和 V 关于 τ 的互信息量函数

$$I(\tau) = 2 \sum_{i=1}^m P_i \log P_i - \sum_{i=1}^m \sum_{j=1}^n P_{ij}(\tau) \log P_{ij}(\tau). \quad (8)$$

式中 $P(x)$ 为事件 x 发生的概率。

3) 作出时间延迟与互信息量之间的关系图,最佳时间延迟即为关系图中平均互信息量取第一个局部最小值时所对应的时间延迟值。

2.2 嵌入维数 m 的计算

嵌入维数 m 是使原始吸引子和重构后吸引子等价的重要参量。 m 选择过小,将使得重构得到的多维空间因混沌吸引子发生折叠甚至自相交以至不能完全涵盖原序列的特征; m 选择过大,将使得计算复杂,同时放大舍入噪声的影响。本文采用Cao氏算法来计算交通流时间序列的嵌入维数,其步骤如下^[8-10]。

1) 设 m_0 维空间中第 i 个相点矢量为

$$\mathbf{Q}_{m_0}(i) = [q(i), q(i-\tau), q(i-2\tau), \dots, q(i-(m_0-1)\tau)]^T, \quad (9)$$

计算其到最近邻点 $\mathbf{Q}_{m_0}^{NN}(i)$ 的欧式距离,为

$$R_{m_0}(i) = \|\mathbf{Q}_{m_0}(i) - \mathbf{Q}_{m_0}^{NN}(i)\|_0$$

2) 将空间维数增加到 m_0+1 ,计算其空间中第 i 个相点矢量到其最近邻点的欧式距离,为

$$R_{m_0+1}(i) = \|\mathbf{Q}_{m_0+1}(i) - \mathbf{Q}_{m_0+1}^{NN}(i)\|_0$$

3) 计算下式

$$E(m_0) = \frac{1}{N - m_0\tau} \sum_{i=1}^{N - m_0\tau} \frac{\|\mathbf{Q}_{m_0+1}(i) - \mathbf{Q}_{m_0+1}^{NN}(i)\|_0}{\|\mathbf{Q}_{m_0}(i) - \mathbf{Q}_{m_0}^{NN}(i)\|_0}, \quad (9)$$

$$E_1(m_0) = E(m_0 + 1) / E(m_0) \quad (10)$$

4) 增加嵌入维数 $m=m_1 > m_0$,重复步骤1~3,画出嵌入维数 m 取不同值时 $E_1(m)$ 与 m 的关系图。当 $E_1(m)$ 趋于饱和,即 $E_1(m)$ 在一定误差范围内不再变化时,其所对应的 m 值即为最佳嵌入维数。

2.3 最大Lyapunov指数的计算

最大Lyapunov指数是离散时间序列动力学特性中最为重要的参量之一。最大Lyapunov指数大于零,表明离散时间序列存在混沌特性,同时最大Lyapunov指数越小,则该混沌序列具备的可预测性越好。本文采用Wolf方法求解相空间重构后交通流序列的最大Lyapunov指数来分析其混沌特性和可预测性,计算步骤如下^[8-10]。

1) 根据选定的延迟时间 τ 和嵌入维数 m ,对交通流时间序列进行相空间重构。

2) 设变量 n_0 , n_i 和 n_M 分别为初始时间点、任意时间点和最终时间点。首先计算 $\mathbf{Q}(n_0)$ 与其最近邻点 $\mathbf{Q}_0(n_0)$ 的最短距离 $L_0 = \|\mathbf{Q}(n_0) - \mathbf{Q}_0(n_0)\|$,随着时间变化到时间点 n_i , $L'_0 = \|\mathbf{Q}(n_i) - \mathbf{Q}_0(n_i)\|$ 大于某一规定值 $\varepsilon(\varepsilon > 0)$,保留 $\mathbf{Q}(n_i)$,并找到其最近邻点 $\mathbf{Q}_i(n_i)$,使得 $L_i = \|\mathbf{Q}(n_i) - \mathbf{Q}_i(n_i)\| < \varepsilon$,重复上述过程,直到时间终点 n_M 。

3) 根据式(11)计算最大Lyapunov指数

$$\lambda = \frac{1}{n_M - n_0} \sum_{i=0}^M \ln \frac{L'_i}{L_i} \quad (11)$$

3 实验与分析

3.1 实验数据和评价指标

本研究采用的交通流数据为2010年1月11日—2010年1月15日(周一至周五)间,北京市西直门桥处方向为至西向东断面的混合交通流流量数据,如图2所示。数据的采样间隔为6 min,共1 200个采样点数据。从图中可以看出,交通流量每天都遵循“从晚低谷上升到早高峰,再下降到次低谷,接着再上升至晚高峰,最后持续下降至凌晨最低谷”的规律,带有一定的确定性和周期性。




图2 交通流时间序列图

Fig. 2 Traffic flow time series diagram

为了全面评估2种神经网络的预测精度,本文采用平均绝对偏差 ε_{mad} 、均方根误差 $\varepsilon_{\text{rmse}}$ 、平均绝对百分比误差 $\varepsilon_{\text{mape}}$ 和标准均方根误差 $\varepsilon_{\text{nrmsc}}$ 等4个误差指标对预测结果进行评价。各误差指标的计算公式如下[6]:

$$\varepsilon_{\text{mad}} = \frac{1}{(b-a)} * \sum_{n=a+1}^b |\hat{q}(n) - q(n)|, \quad (12)$$

$$\varepsilon_{\text{rmse}} = \sqrt{\frac{1}{(b-a)} \sum_{n=a+1}^b (\hat{q}(n) - q(n))^2}, \quad (13)$$

$$\varepsilon_{\text{mape}} = \frac{1}{(b-a)} * \sum_{n=a+1}^b \frac{|\hat{q}(n) - q(n)|}{|q(n)|}, \quad (14)$$

$$\varepsilon_{\text{nrmsc}} = \sqrt{\frac{1}{(b-a) * \sigma^2} \sum_{n=a+1}^b (\hat{q}(n) - q(n))^2}. \quad (15)$$

式(12)~(15)中: $\hat{q}(n)$ 为实际预测值; $q(n)$ 为期望预测值; σ^2 为交通流时间序列的方差; $a+1$ 为测试样

本的起始时间点; b 为测试样本的最终时间点。

本文所有仿真结果均在Intel双核T5470,1.6 GHz,内存2 GB的MATLAB R2009a仿真计算环境下完成。

3.2 实验结果

利用互信息量函数法和Cao式方法计算交通流时间序列延迟时间和嵌入维数的结果如图3和图4所示。从图3可以看出,当 $\tau=1$ 时,平均互信息量到达第一个极小点,因此由互信息量法的原理可知, $\tau=1$ 即为最佳的时间延迟。从图4可以看出,当嵌入维数 $m \geq 4$ 时,曲线趋于饱和,所以 $m=4$ 即为最佳嵌入维数。




图3 交通流时间序列的互信息量函数

Fig. 3 Mutual information function of traffic flow time series




图4 Cao氏法计算嵌入维数

Fig. 4 Calculating embedding dimension by Cao's method

选取 $\tau=1$ 和 $m=4$,对交通流时间序列进行相空间重构后,利用Wolf方法求得的最大Lyapunov指数 $\lambda=0.106 0 > 0$,可见相空间重构后的交通流时间序列具有混沌特性,由于 λ 较小,所以其具有较好的可预测性。

本文研究所用的交通流数据的采样间隔为6 min,共1 200个采样点数据。预测方法采用前4 d的交通流数据作为网络训练样本,最后1 d的交通流数据作为测试样本。由于选取的延迟时间 $\tau=1$,嵌入维数 $m=4$,所以将1 200个采样点数据重构成大小为 $4 * 1 196$ 的输入序列矩阵和大小为 $1 * 1 196$ 的输出序列矩阵,其中用于神经网络训练的输入矩阵大小为 $4 * 956$,输

出目标序列矩阵大小为 1×956 ; 用于检测神经网络预测效果的输入序列矩阵大小为 4×240 , 输出目标序列矩阵大小为 1×240 。为了便于快速收敛, 首先对采集到的原始数据进行归一化处理, 使得数据样本值落在 $0 \sim 1$ 之间。

回声状态网络的参数设置如下: 输入层神经元个数 $A=4$, 隐含层神经元个数 $B=50$, 输出层神经元个数 $C=1$, 储备池谱半径 $R=0.75$, 输入缩放系数 $F_{in}=0.1$, 稀疏度 $D=5\%$, 储备池激活函数为 Sigmoid 函数, 输出激活函数为恒等函数。为了避免输出权值矩阵 W^{out} 在训练时的初始状态不稳定, 将预测输出序列的前 20 个值舍弃, 所以预测输出序列最终的输出值为 220 个。

Elman 神经网络的参数设置如下^[12]: 输入层神经元数目为 4, 输出层神经元数目为 1, 隐含层神经元个数为 30。隐含层的激活函数为 tansig, 输出层的激活函数为 purelin, 训练函数为 traingdx, 训练次数为 3 000, 目标值为 0.000 1, 学习速率为 0.1。

图 5 给出了回声状态网络对交通流进行预测的结果, 图 6 给出了 Elman 神经网络对交通流进行预测的结果。表 1 给出了回声状态网络和 Elman 神经网络对交通流进行预测的误差统计结果。




图 5 回声状态网络的预测结果

Fig. 5 Prediction results of ESN




图 6 Elman神经网络的预测结果

Fig. 6 Prediction results of Elman neural network

从图 5 和图 6 可以看出, 采用两种神经网络对交通流进行预测, 其预测结果均能较好反映交通流变

化的趋势和规律, 实际预测值曲线与期望预测值之间拟合较好。预测的误差统计见表 1。

表 1 预测的误差统计

误差统计 指标模型	$\epsilon_{rmse}/$ (veh.6 min ⁻¹)	$\epsilon_{mad}/$ (veh.6 min ⁻¹)	$\epsilon_{mape}/$ %	$\epsilon_{nrms}/$ %	训练 时间/s
回声状态网络	26.58	19.23	11.14	18.74	0.79
Elman 神经网络	26.51	19.15	12.56	18.02	16.00

表 1 表明, 采用两种神经网络对交通流时间序列的预测精度较高, 均可以满足交通控制和诱导所需要的预测精度。但采用回声状态网络进行预测时, 其训练时间仅为 Elman 神经网络的 4.93%。

4 结论

1) 本文采用 G-P 算法和 Cao 氏方法对短时交通流时间序列进行了延迟时间 τ 和嵌入维数 m 的计算, 并对相空间重构后的交通流序列采用 Wolf 方法计算其最大 Lyapunov 指数。结果表明, 短时交通流序列具有混沌特性, 能够对其进行精度较高的预测。

2) 本文分别采用回声状态网络和 Elman 神经网络对交通流时间序列进行了预测。实验结果表明, 两种神经网络均能够较好地反映交通流变化的趋势和规律, 预测精度较高。但回声状态网络的训练速度较 Elman 网络有了较大的提高, 非常适用于对实时性要求高的预测环境。

参考文献:

- [1] Jaeger H, Haas H. Harnessing Nonlinearity: Predicting Chaotic Systems and Saving Energy in Wireless Telecommunication[J]. Science, 2004, 304(5667): 78-80.
- [2] 董春娇, 邵春福, 熊志华, 等. 基于 Elman 神经网络的道路网短时交通流预测方法[J]. 交通运输系统工程与信息, 2010, 10(1): 145-151.
Dong Chunjiao, Shao Chunfu, Xiong Zhihua, et al. Short Term Traffic Flow Forecasting of Road Network Based on Elman Neural Network[J]. Journal of Transportation Systems Engineering and Information Technology, 2010, 10(1): 145-151.
- [3] 何定, 徐鹏. Elman 与 BP 神经网络应用于交通流预测的对比研究[J]. 工业工程, 2010, 13(6): 97-100.
He Ding, Xu Peng. Comparative Study on the Application of Elman and BP Neural Network to Traffic Flow Prediction [J]. Industrial Engineering Journal, 2010, 13(6): 97-100.
- [4] 彭宇, 王建民, 彭喜元. 基于回声状态网络的时间序列预测方法研究[J]. 电子学报, 2010, 38(2A): 148-154.
Peng Yu, Wang Jianmin, Peng Xiyuan. Researches on Time Series Prediction with Echo State Networks[J]. Acta

- Electronica Sinica, 2010, 38(2A): 148-154.
- [5] 罗熊, 黎江, 孙增圻. 回声状态网络的研究进展[J]. 北京科技大学学报, 2012, 34(2): 217-222.
Luo Xiong, Li Jiang, Sun Zengqi. Review on Echo State Network[J]. Journal of University of Science and Technology Beijing, 2012, 34(2): 217-222.
- [6] 杨飞. 基于回声状态网络的交通流预测模型及其相关研究[D]. 北京: 北京邮电大学, 2012.
Yang Fei. Traffic Flow Prediction Model Based on Echo State Networks and Related Research[D]. Beijing: Beijing University of Posts and Telecommunications, 2012.
- [7] Takens F. Detecting Strange Attractors in Turbulence[J]. Lecture Notes in Mathematic, 1981, 898: 366-381.
- [8] 王海燕, 卢山. 非线性时间序列的分析及其应用[M]. 北京: 科学出版社, 2006: 33-40.
Wang Haiyan, Lu Shan. Nonlinear Time Series Analysis and Its Application[M]. Beijing: Science Press, 2006: 33-40.
- [9] 吕金虎, 陆君安, 陈士华. 混沌时间序列分析及其应[M]. 武汉: 武汉大学出版社, 2002: 57-80.
Lü Jinhū, Lu Jun'an, Chen Shihua. Chaotic Time Series Analysis and Its Application[M]. Wuhan: Wuhan University Press, 2002: 57-80.
- [10] Wang Jin, Shi Qixin, Lu Huapu. The Study of Short-Term Traffic Flow Forecasting Based on Theory of Chaos // [C] IEEE Intelligent Vehicles Symposium. Las Vegas: IEEE Press, 2005: 869-874.
- [11] 张均良, 曹晶, 蒋世忠. 神经网络实用教程[M]. 北京: 机械工业出版社, 2008: 52-57.
Zhang Junliang, Cao Jing, Jiang Shizhong. Neural Network Practical Tutorial[M]. Beijing: China Machine Press, 2008: 52-57.
- [12] 朱凯, 王正林. 精通 MATLAB 神经网络[M]. 北京: 电子工业出版社, 2010: 375-394.
Zhu Kai, Wang Zhenglin. Proficient in MATLAB Neural Network[M]. Beijing: Publishing House of Electronics Industry, 2010: 375-394.

(责任编辑: 申剑)

(上接第 39 页)量 Kinect 深度图像上具有重要的参考价值。

参考文献:

- [1] Ning X P, Guo G D. Assessing Spinal Loading Using the Kinect Depth Sensor: A Feasibility Study[J]. IEEE Sensors Journal. 2013, 13(4): 1139-1140.
- [2] Sun Qi, Tang Yanlong, Hu Ping, et al. Kinect-Based Automatic 3D High-Resolution Face Modeling[C]// Proceedings of 2012 International Conference on Image Analysis and Signal Processing, Hangzhou: IASP Press, 2012, 382-385.
- [3] 余涛. Kinect 应用开发实战: 用最自然的语言与机器对话[M]. 北京: 机械工业出版社, 2012: 220-221.
Yu Tao. Kinect Application Programming: Dialogue with Machine in Natural Language[M]. Beijing: Mechanical Industry Press, 2012: 220-221.
- [4] Lee Sang-Beom, Ho Yo-Sung. Real-Time Stereo View Generation Using Kinect Depth Camera[C]//Process. Assoc. Annu. Summit Conf. Xi'an: [s.n.], 2011: 1153-1156.
- [5] 董鸿燕. 边缘检测的若干技术研究[D]. 长沙: 国防科学技术大学, 2008.
Dong Hongyan. Research on Some Techniques in Edge Detection[D]. Changsha: National Defense University, 2008.
- [6] Karsli F, Kahya O. Detecting the Buildings from Airborne Laser Scanner Data by Using Fourier Transform[J]. Experimental Techniques. 2012, 36(1): 5-17.
- [7] 石俊涛, 朱英, 楚晓丽, 等. 基于灰色关联度和Prewitt算子的边缘检测新方法[J]. 微计算机信息. 2010, 10(26): 214-216.
Shi Juntao, Zhu Ying, Chu Xiaoli, et al. A Novel Approach of Edge Detection Based on Gray Correlation Degree and Prewitt Operator[J]. Microcomputer Information. 2010, 10(26): 214-216.
- [8] Li Fengling. Study on the New Weighted Median Filter Algorithm for Image Processing[J]. Journal of Convergence Information Technology. 2012, 7(16): 418-424.

(责任编辑: 申剑)