

基于小波和多维重构的 BP 神经网络交通流短时预测

曹洁^{1,2} 沈钧珥¹ 张红¹ 侯亮¹ 陈作汉¹

¹(兰州理工大学计算机与通信学院 甘肃 兰州 730050)

²(甘肃省制造业信息化工程研究中心 甘肃 兰州 730050)

摘要 针对采集过程中噪声影响以及交通流时间序列的强相关性,提出一种基于小波和多维重构的 BP 神经网络交通流短时预测方法。运用启发式小波降噪法对原始交通流数据进行降噪处理,剔除数据中的噪声;基于 C-C 法将交通流数据进行多维度相空间重构,充分挖掘交通流的多维变化特性;构建多维度的 BP 神经网络进行交通流短时预测研究。运用 2 400 组数据进行实验,并与传统的 BP 神经网络、Elman 神经网络以及 SVM 进行对比。实验结果表明,该方法具有较高的预测精度,绝对误差降低约 2.408 0,均方误差降低约 26.597 2。

关键词 小波降噪 相空间重构 BP 神经网络 短时交通流预测

中图分类号 TP18

文献标识码 A

DOI:10.3969/j.issn.1000-386x.2018.12.012

SHORT-TERM TRAFFIC FLOW FORECASTING BASED ON BP NEURAL NETWORK WITH WAVELET AND MULTIDIMENSIONAL RECONSTRUCTION

Cao Jie^{1,2} Shen Juner¹ Zhang Hong¹ Hou liang¹ Chen Zuohan¹

¹(College of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, Gansu, China)

²(Gansu Manufacturing Information Engineering Research Center, Lanzhou 730050, Gansu, China)

Abstract For the influence of noise in the process of traffic data collection and the strong correlation of traffic flow time series, we proposed a short-term traffic flow prediction method based on BP neural network with wavelet and multidimensional reconstruction. We adopted heuristic wavelet denoising method to reduce noise in the original data of traffic flow, and eliminated noise from the data. Based on C-C method, traffic flow data was reconstructed by multi-dimensional phase space, and the multi-dimensional change characteristics of traffic flow were fully explored. And a multi-dimensional BP neural network was constructed for the short-term prediction of traffic flow. The experiment was carried out with 2 400 sets of data and compared it with the traditional BP neural network, Elman neural network and SVM. The experimental results show that the method has higher prediction accuracy, and the absolute error decreases by about 2.408 0, and the mean square error decreases by about 26.597 2.

Keywords Wavelet denoising Phase space reconstruction BP neural network Short-term traffic flow prediction

0 引言

随着城市化进程飞速发展,交通拥堵已成为阻碍城市发展的瓶颈,且困扰着市民的出行。有效、合理的短时交通流预测可以为交通管理者和交通参与者提供实时、准确的交通信息,为交通管理和出行选择提供依据。短时交通流预测是交通流预测的一个重要组成部

分,是城市交通智能化的重要依据。近年来,国内外众多学者对提高交通流的预测精度展开了深入研究。文献[1]中通过思维进化算法中的“群体寻优”取代“个体寻优”对 BP 神经网络中的权值和阈值进行优化,对交通流预测精度提高。文献[2]中运用传统的小波固定阈值降噪法对交通流进行降噪处理,再用小波神经网络进行预测,获得较好的预测效果。文献[4]中通过选取一个小波基函数替换 BP 神经网络中隐含层结

点的传递函数来提高预测精度。文献[5]中运用BP神经网络对高速公路进行预测研究。以上研究表明, BP神经网络在识别复杂非线性交通流问题中有着巨大的优越性,但也存在稳定性差、精度容易受到训练数据中噪声影响的缺点。

基于上述分析,本文提出了一种基于小波和多维重构的BP神经网络预测方法。首先选取启发式小波阈值降噪法对交通流数据进行分析、处理,提高交通流数据质量;其次采用C-C方法对交通流数据进行相空间重构,获取多维交通流信息;最后构建多维度BP神经网络模型对短时交通流进行研究分析。

1 交通流数据预处理

由于交通流数据在采集的过程中容易受到各种噪声的影响,导致后期进行预测精度较低。小波阈值降噪法能够有效去除数据中的噪声,保留原始特征,且计算简单高效。因此,选用小波阈值降噪法对采集到的交通流数据进行降噪处理。小波阈值降噪是一种建立在小波变换多分辨分析基础上的算法,根据噪声与信号在不同频带上的小波分解系数具有不同强度分布的特点,去除各频带上的噪声信号所对应的小波系数,进而保留原交通流信号中的小波分解系数,然后对降噪后的系数进行小波重构,获取纯净信号。为了能更好的反映出交通流数据特性,本文采用启发式小波阈值降噪法,将有用信号和噪声信号分离,进而提高交通流数据质量。

1.1 小波降噪原理

对于含有噪声的一维信号可表示为:

$$f(t) = s(t) + \delta e(t) \quad t = 1, 2, \dots, n-1 \quad (1)$$

式中: $f(t)$ 为噪声信号, $s(t)$ 为实际数据信号, $e(t)$ 为噪声, δ 为噪声相关系数, n 为信号长度。

具体小波分析运用中,通常近似显示为低频信号或为相对平稳的信号;细节则表现为高频信号,噪声分量一般集中于高频信号中。小波降噪的基本过程为:先对含有噪声信号小波变换的分解,选择分解层数为4层进行阐述,经分解后的信号其噪声部分分量通常在 $cD1$ 、 $cD2$ 、 $cD3$ 、 $cD4$ 中, cD 及 cA 分别为信号经小波变换分解后的细节系数和近似系数,接着对细节系数 cD 分量采取适当的阈值实行降噪,最后通过将降噪后的近似系数 cA 以及各层细节系数 cD 进行重构,从而得到降噪后的信号。

1.2 启发式小波交通流降噪

小波降噪阈值的选取是提高小波降噪能力的关

键,目前常见的小波阈值选择方法有:固定阈值估计(Sqtwolog)、极值阈值估计(Minimaxi)、无偏似然估计(Rigrsure)以及启发式估计(Hesusure)等。极值阈值估计和无偏似然估计方法只能对低频段的噪声信号有着较好的降噪效果,且极值阈值估计降噪时间较长。而启发式阈值估计是将固定阈值估计和无偏似然估计结合起来,能够获取最佳的预测效果,其步骤为:

Step 1 一维信号的小波分解。选择合适小波基函数,对一维信号 $f(t)$ 进行 N 层分解。

Step 2 高频系数 cD 的阈值量化。设定阈值标准,对分解后得到的 cD 进行量化处理,阈值量化的效果直接影响降噪的效果。固定阈值为:

$$\lambda = \sqrt{2\log(N)} \quad (2)$$

无偏风险阈值方法主要是由Stein无偏似然估计原理所估计出的最小风险量所对应的小波系数确定自适应阈值。其原理为:

通过将信号 $f(t)$ 中各个元素取绝对值后平方,再由小到大排列,进而得到以下新的信号序列,即:

$$f(k) = (\text{sort}(|f|))^2 \quad k = 0, 1, \dots, N-1 \quad (3)$$

取阈值 $f(k)$ 的第 k 个元素的平方根,即:

$$\lambda_k = \sqrt{f(k)} \quad (4)$$

则该阈值产生的风险:

$$R(k) = [N - 2k + \sum_{i=1}^k f(i) + (N - k)f(N - k)]/N \quad (5)$$

根据 $R(k)$,寻找最小风险点所对应的 k_{\min} 值,其Rigrsure的阈值则定义为:

$$\lambda_k = \sqrt{f(k_{\min})} \quad (6)$$

假设信号 $f(t)$ 长度为 N ,通过无偏似然估计和固定阈值方法分别得到的阈值,令:

$$\text{crit} = \sqrt{\frac{1}{N} \left(\frac{\ln N}{\ln 2} \right)^3} \quad (7)$$

$$\text{eta} = \left[\sum_{k=1}^N |f_k|^2 - N \right] / N \quad (8)$$

若 $\text{eta} < \text{crit}$,则选用固定阈值估计(Sqtwolog)阈值;若 $\text{eta} \geq \text{crit}$,则选取固定阈值估计(Sqtwolog)和无偏似然估计(Rigrsure)中较小者作为准则选定的阈值。

Step 3 一维信号的恢复。将启发式阈值量化后的高频系数 cD 与小波分解的第 N 层低频系数 cA 进行重构,获取降噪后的信号。

2 交通流多维度信息提取

交通流作为典型的混沌时间序列,具有较强的非

线性。本文运用 C-C 法对所用交通数据进行重构,映射出交通数据中的多维信息。为了体现交通流是否具有短期预测性,本文在相空间重构的基础上,选用小数据量法计算得到交通流的最大李雅普诺夫 (Lyapunov) 指数,进一步对具有混沌特性的短时交通流进行特定分析。

2.1 交通流相空间重构

运用检测器、摄像头等所采集的实时交通流数据呈现一维时间序列,无法准确地反映出交通流复杂特性。因此,将一维交通流时间序列扩展为多维交通流时间序列显得极为重要。对一维交通流时间序列 $x(t_1), x(t_2), \dots, x(t_n)$ 进行相空间重构,得到多维时间序列:

$$x(t_i) = [x(t_i), x(t_{i+\tau}), \dots, x(t_{i+(m-1)\tau})] \quad (9)$$

式中:时间延迟为 τ ,嵌入维数为 m ,以及相点数为 $x(t_i), i=1, 2, \dots, n-(m-1)\tau$ 。

由式(9)可得,时间延迟 τ 以及嵌入维数 m 的确定是相空间重构的关键。经研究表明,时间延迟 τ 、嵌入维数 m 以及相空间重构中的时间窗宽 τ_w 这三者之间存在一定的联系,Kugiumtzis 曾提出延迟时间 τ 嵌入维数 m 以及时间窗宽 τ_w 它们都不是独立地存在,三者存在一定的相互关系 $\tau_w = (m-1)\tau$ ^[8]。本文运用 C-C 法来实现多维交通流时间序列的提取,其具体步骤如下:

Step 1 获取一维时间序列数据,计算时间序列的标准差 δ ,将交通流数据重新分解为 t 个不相交的时间序列,确定 N 。

Step 2 当 $N \rightarrow \infty$ 时,计算 $s(m, r, t)$ 和 $\Delta S(m, t)$,其中时间变量 $t \in [1, 200]$:

$$s(m, r, t) = \frac{1}{t} \sum_{s=1}^t [C_s(m, r, t) - C_s^m(1, r, t)] \quad (10)$$

$$m = [2, 5]$$

$$\Delta S(m, t) = \max\{S(m, r, t)\} - \min\{S(m, r, t)\} \quad (11)$$

Step 3 计算下列三式:

$$\bar{S}(t) = \frac{1}{16} \sum_{m=2}^5 \sum_{i=1}^4 S(m, r_i, t) \quad (12)$$

$$\Delta \bar{S}(t) = \frac{1}{4} \sum_{m=2}^5 \Delta S(m, t) \quad (13)$$

$$S_{\text{cor}}(t) = \Delta \bar{S}(t) + |\bar{S}(t)| \quad (14)$$

式中,时间延迟 τ 所对应的为 $\Delta \bar{S}(t)$ 的第一个局部极小点;同时,延迟时间窗口 τ_w 所对应的为 $S_{\text{cor}}(t)$ 的全局最小点;由 $\tau_w = (m-1)\tau$,即可得到嵌入维数 m 。

2.2 交通流可预测性分析

Lyapunov 指数是检验系统是否存在混沌现象的重要特征量,文献[9]等研究表明,最大 Lyapunov 指数可

用来描述系统运动对初始条件的敏感性。若获取的最大 Lyapunov 指数大于零时,则表明该交通流时间序列具有混沌特性,可以进行短时交通流预测。

通常计算最大 Lyapunov 指数有很多的方法,如:Wolf 法、Jacobian 法、P-范数法以及小数据量法等。小数据量方法计算量小、计算精度高、相对容易操作,在识别混沌特性方面具有一定的优越性。其具体步骤:

Step 1 对时间序列 $\{x(t_i), i=1, 2, \dots, N\}$ 进行 FFT 变化,获取时间序列平均周期。

Step 2 运用 C-C 法获取时间延迟 τ 和时间窗宽 τ_w ,计算得到嵌入维数 m ,并进行相空间重构 $\{Y_j, j=1, 2, \dots, M\}$ 。

Step 3 寻求相空间中每个点 Y_j 所对应的最近邻近点 $Y_{j'}$ 并进行相分离,即:

$$d_j(0) = \min_j \|Y_j - Y_{j'}\| \quad |j-j'| > P \quad (15)$$

Step 4 计算相空间中最近邻近点 $Y_{j'}$ 所对应的 i 个离散时间步间的距离 $d_j(i)$:

$$d_j(i) = |Y_{j+i} - Y_{j'+i}| \quad (16)$$

式中: $i=1, 2, \dots, \min(M-j, M-j')$ 。每个 i 求出所有 j 的 $Ind_j(i)$ 的平均 $y(i)$,即:

$$y(i) = \frac{1}{q\Delta t} \sum_{j=1}^q Ind_j(i) \quad (17)$$

式中: q 表示 $d_j(i)$ 不为零的个数,运用最小二乘法做出回归直线的斜率就是最大 Lyapunov 指数。

3 多维 BP 神经网络预测模型

BP 神经网络是由信号向前传递、误差反向传播的一种双向传递的多层前馈神经网络。它具有强大的适应能力,能够自行地挖掘出数据中的潜在规律,其主要由输入层,隐含层以及输出层构成,基本结构图如图 1 所示。




图 1 BP 神经网络结构图

其中, i 是输入层节点, x_i 是输入, j 是隐含层节点, x_j 是隐含层输入, x'_j 为隐含层输出, k 是输出层节点, y_k 是输出, w_{ij} 对应输入层与隐含层间的权值, w_{jk} 对应输出层

与隐含层间的权值。

信号前向传播和误差反向传播是 BP 神经网络最基本的两个部分。具体如下:

Step 1 前向传播:获取 BP 神经网络隐含层输入 x_j 的所有输入个数的加权和,即:

$$x_j = \sum_i w_{ij} x_i \quad (18)$$

隐含层的输出: $x'_j = f(x_j)$, 其中 $f(\cdot)$ 为激活函数;

输出层为: $y_k = \sum_j w_{jk} x'_j$ 。

Step 2 误差反向传播:反馈误差按梯度下降学习方式对各层权值及阈值进行修正,使网络预测输出不断逼近期望输出。

获取输出 y_k 和理想值 y'_k 之间的误差 e_k 为:

$$e_k = y'_k - y_k \quad (19)$$

BP 网络误差性能指标函数为:

$$E = \frac{1}{2} e_k^2 \quad (20)$$

输出层与隐含层之间的权值为:

$$\Delta w_{jk} = -\eta \frac{\partial E}{\partial w_{jk}} = \eta \cdot e_k \cdot \frac{\partial y_k}{\partial w_{jk}} \eta \cdot e_k \cdot x'_j \quad (21)$$

式中: η 为学习率, $\eta \in [0, 1]$ 。

更新输出层与隐含层间的权值:

$$w'_{jk} = w_{jk} + \Delta w_{jk} \quad (22)$$

输入层与隐含层间的权值 w_{ij} 的学习算法:

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \cdot e_k \cdot \frac{\partial y_k}{\partial w_{ij}} \eta \cdot e_k \cdot w_{jk} \cdot x'_j (1 - x'_j) \cdot x_i \quad (23)$$

更新输入层与隐含层间的权值:

$$w'_{ij} = w_{ij} + \Delta w_{ij} \quad (24)$$

BP 神经网络主要是通过不断的迭代进行参数择优,一次完成的训练包括信号的前向传播以及误差反向传播。通过参数调整达到最优的训练网络,输入测试数据,获得相应的结果。

4 实验与分析

本文研究所用数据源于明尼苏达大学交通实验室平台所公布的交通流数据。通过 100 个检测器获取 2016 年 1 月 1 日 - 2016 年 1 月 5 日的数据,如图 2 所示,数据采样周期以 3 分钟为准,每天获取 480 个数据,5 天总获取 2 400 个数据。为了能使预测误差减小,采用函数 `mapminmax` 将预测数据处于 $[0, 1]$

之间。




图 2 原始交通流量

4.1 交通流数据预处理

为了更好地消除交通流数据中产生的高斯白噪声,选用启发式阈值进行降噪处理。通过实验发现 5 层小波分解使得数据过于平滑,不能反映出交通数据中所隐藏的信息。因此,为了更好地反映交通流数据的原有特征,则使用小波工具箱中的 `sym8` 小波函数进行 4 层分解、降噪、重构。降噪效果如图 3 所示。通过对比可得降噪后的数据显得更加平滑。




图 3 小波降噪交通流量

4.2 交通流数据空间重构

实验获取交通流时间序列的长度为 2 400, 计算交通流量时间序列的标准差:取 $2 \leq m \leq 5, 0.5\sigma \leq r \leq 2\sigma, 1 \leq t \leq 200$ 。通过 C-C 法得到 3 个统计量分别为 $s(t)$ 、 $delt_s(t)$ 、 $s_cor(t)$, 其中 $s(t)$ 为所有子序列的统计量 $S(m, N, r, t)$ 的均值。时间延迟 τ 由 $delt_s(t)$ 的第一个局域极小值点所对应的时间所决定; τw 是通过 $s_cor(t)$ 的全局最小值所对应的时间来确定。通过图 4 所示, 当 $t = 34$ 时, $delt_s(t)$ 取得第一个局域极小值, 因此可以得到 $\tau = 34$ 。从 $s_cor(t)$ 曲线中可得, 当 $t = 128$ 时取得全局最小值, 则 $\tau w = 128$ 。通过公式 $\tau w = (m - 1) \times \tau$ 可得 $m = 4.7647$, 本文进行相空间重构时取整数 $m = 5$, 通过公式 $M = N - (m - 1) \times \tau$ 可以得出相空间点为 2 264。运用小数据量方法获得的最大 Lyapunov 指数 $\lambda = 0.01683$, 反映出重构后的交通流时间序列具有混沌特性, 因此交通流具有较好的短时预

测性。




图 4 多维交通数据参数关系图

4.3 多维 BP 神经网络预测

通过检测器获得 2 400 组数据,根据 C-C 方法估算得到嵌入维数和延迟时间。经相空间重构后,任意选取相空间点中 75% 相点进行 BP 神经网络模型训练,25% 相点作为 BP 神经网络预测。

由于交通流具有混沌特性,将嵌入维数作为神经网络输入层个数具有较佳的预测性,因此,BP 神经网络输入层数目为 5。隐含层神经元数大小对预测精度有着较大的影响,隐含层神经元数较少,导致网络学习效果不佳,突变性变强,预测效果较低;隐含层神经元数过多,则将导致网络训练时间过长,收敛较慢网络易过度拟合,且其容错性降低。本文通过 $h = \sqrt{n + m} + a$ ($1 \leq a \leq 12$) 以及多次实验相结合获得隐含层神经元数目为 14,其中 m 为输入层个数, n 为输出层个数;输出层神经元数目为 1;隐含层的激活函数为 purelin,输出层的激活函数为 tansig,为了加快收敛和防止陷入局部最小,引入训练函数 traingdx;通过不断实验,选择最优训练次数为 3 000,目标值为 0.000 01 以及学习速率为 0.01。

图 5 显示未经启发式小波降噪的 BP 神经网络预测结果;图 6 显示 Elman 神经网络预测结果;图 7 显示小波降噪 + 多维 BP 神经网络预测。通过对比显示,本文的预测方法结果能更好的反映出交通流变换特性。




图 5 BP 神经网络预测结果




图 6 Elman 神经网络预测结果




图 7 小波降噪 + 多维 BP 神经网络预测

4.4 交通流预测模型评价

为了能更好地显现出短时交通流模型的优越性,本文选用平均相对误差、均方误差以及平均绝对误差等进行预测评估。

平均相对误差:

$$MAPE = \frac{1}{N} \sum_t \left| \frac{Y_{pred}(t) - Y_{yeat}(t)}{Y_{yeat}(t)} \right| \times 100\% \quad (25)$$

均方误差:

$$MSE = \sqrt{(Y_{pred}(t) - Y_{yeat}(t))^2} \quad (26)$$

平均绝对误差:

$$MAE = \frac{1}{N} \sum_t |Y_{pred}(t) - Y_{yeat}(t)| \quad (27)$$

式中: $Y_{yeat}(t)$ 表示在 t 时刻的交通流量的实测值; $Y_{pred}(t)$ 表示预测值, N 为样本个数。

$MAPE$ 的值反映预测值与实际值的偏离程度, $MAPE$ 越小,则显示预测值与实际值偏离程度小且预测效果越好;通过 MSE 的值来反映误差分的分布情况, MSE 值越小,误差分布就越集中且预测效果就越好。表 1 为误差对比。

表 1 实验误差对比

预测模型	模型评价		
	MAPE	MSE	MAE
BP 神经网络	22.466 1	40.249 1	5.007 6
Elman 神经网络	21.313 8	29.654 7	4.146 3
支持向量机(SVM)	22.469 7	22.322 5	3.978 9
小波降噪 + BP 神经网络	21.182 4	13.641 9	2.509 6

- 智能排队叫号系统设计[J]. 计算机测量与控制, 2017, 25(1):137-140.
- [2] 张银娟, 陈珏, 杨骅. 综合性医院患者门诊就医隐私保护需求调查[J]. 解放军医院管理杂志, 2013, 20(6): 533-534.
- [3] 郭志强, 温渤婴. 一种用于教学实验设备的嵌入式无线 Wi-Fi 通信模块设计[J]. 中国教育技术装备, 2017(18): 31-34.
- [4] Chaitanya B V S S, Sekhar T C, Ramesh N V K. IOT based smart IR device using CC3200[J]. Indian Journal of Science & Technology, 2016, 9(16).
- [5] 陈颖莹. 芯片上的网络 TI SimpleLink Wi-Fi 让联网如此简单[J]. 电子技术应用, 2014, 40(7):2-2.
- [6] Zhu H T, Tang Q Y, Chiu L, et al. Design of a broadband CPWG to dielectric ridge waveguide transition for terahertz circuits[C]//IEEE International Workshop on Electromagnetics. IEEE, 2013:108-111.
- [7] 李继军, 聂晓梦, 甄威, 等. 显示技术比较及新进展[J]. 液晶与显示, 2018, 33(1):74-84.
- [8] Govil K, Chan E, Wasserman H. Comparing algorithm for dynamic speed-setting of a low-power CPU[C]//Proceedings of the 1st annual international conference on Mobile computing and networking. ACM, 1995:13-25.
- [9] TEXAS INSTRUMENTS. CC3100/CC3200 SimpleLink Wi-Fi Internet-on-a-Chip: User's Guide[EB/OL]. 2016. <http://www.ti.com/>.
- [10] 金婧, 陈家铨, 王靖天, 等. 基于 Go 语言及 Beego 等开源技术的公务车辆管理系统的设计与实现[J]. 信息通信, 2015(2):140-141.

(上接第 65 页)

通过以上对比分析可得:运用 Elman 神经网络、支持向量机(SVM)以及本文所提出的方法,在所预测的时间段历史数据库有着较好的相似度,但运用本文的方法均方误差最低,达到 2.509 6,且随着交通流数据中噪声的降低,以及交通流的突变性减弱,预测精度得到了进一步的提高。

5 结语

通过启发式阈值降噪实现交通流数据分层降噪有利用充分去除交通流数据中的噪声,大幅度提高数据质量,进而提高预测精度;选用 C-C 法实现交通流多维信息的获取,更加充分反映交通流变化轨迹,并进一步确定了 BP 神经网络输入层个数;最后通过 BP 神经网络模型预测。通过实验误差对比,文中所运用的方法

使均方误差从 40.349 1 降低到 13.641 9,能更好地反映出交通流非线性。但由于单个 BP 神经网络模型泛化能力低,具有一定的随机误差性,下一步结合 Bagging 集成算法对短时交通流预测展开更加进一步的研究。

参 考 文 献

- [1] 季雪美. 基于优化的 BP 神经网络的短时交通流预测算法研究[D]. 青岛:青岛大学,2016.
- [2] 黄晓慧. 基于布谷鸟算法的小波神经网络短时交通流预测研究[D]. 成都:西南交通大学,2016.
- [3] Abouaissa H, Fliess M, Join C. On short-term traffic flow forecasting and its reliability[C]//Ifac-Manufacturing Modelling, Management, and Control. 2016.
- [4] Chai Y, Huang D, Zhao L. A short-term traffic flow prediction method based on wavelet analysis and neural network[C]//2016 Chinese Control and Decision Conference (CCDC). IEEE, 2016:7030-7034.
- [5] 陈丽朝. BP 神经网络在高速公路短时交通流预测中的应用[J]. 信息与电脑(理论版), 2016(22):183-184.
- [6] 张玮玮. 基于聚类分析的 BP 神经网络短时交通流预测方法研究[D]. 重庆:重庆邮电大学,2016.
- [7] 郭中华, 李树庆, 王磊, 等. 自适应阈值的小波去噪改进算法研究[J]. 重庆邮电大学学报(自然科学版), 2015, 27(6):740-744, 750.
- [8] 修妍. 基于混沌相空间重构参数优化的动态神经网络预测模型研究[J]. 科技创新与应用, 2017(23):13-14, 16.
- [9] 邓高, 杨珊, 江时雨. 相空间重构和混沌遗传神经网络融合的矿井涌水量预测研究[J]. 世界科技研究与发展, 2016, 38(5):973-978.
- [10] 范黎林, 符天阳, 孙兰宾, 等. 基于混沌-小波神经网络的公交客流量预测模型研究[J]. 城市公共交通, 2017(9):34-40.
- [11] Abdelatif S, Makhlof D, Roose P, et al. Loop Speed Trap Data Collection Method for an Accurate Short-Term Traffic Flow Forecasting[C]//International Conference on Mobile Web and Information Systems. Springer International Publishing, 2016:56-64.
- [12] 王晓丹, 白云, 李川. 基于统计的我国短时交通流预测模型分析[J]. 现代计算机, 2017(17):31-34.
- [13] 程婷, 叶晓彤. 小波神经网络在短时交通流中的应用[J]. 软件导刊, 2016, 15(1):37-39.
- [14] Ou J, Xia J, Wu Y J, et al. Short-Term Traffic Flow Forecasting for Urban Roads Using Data-Driven Feature Selection Strategy and Bias-Corrected Random Forests[J]. Transportation Research Record Journal of the Transportation Research Board, 2017, 2645:157-167.