

一种基于小波和神经网络的短时交通流量预测

李佩钰

(长安大学 信息工程学院, 陕西 西安 710064)

摘要:针对实际交通流变化的不稳定性和复杂性的特点,应用交通流预测模型获取更准确的交通流信息,是智能交通领域的一个研究热点。提出一种基于小波分析与神经网络结合的预测模型。模型主要思想是通过小波多分辨率分析和Mallat算法对原始交通流数据进行平滑降噪处理,处理过程选用db10小波和软阈值去噪函数使得交通流曲线更加平滑稳定,更能真实反映交通流的真实情况;再采用激活函数为Tan-Sigmoid,训练函数为trainlm,各层神经元节点数为1-12-1的三层BP神经网络对消噪后的交通流数据进行训练,用训练好的预测模型对实际交通流信息进行预测,最后获取准确的交通流信息。实验结果表明,采用小波分析与BP神经网络结合的方法得到的预测结果平均相对误差为0.03%,最大相对误差为0.39,拟合度(EC)达到0.96。仅使用BP神经网络预测模型对交通流数据进行预测后得到的预测结果的平均相对误差为0.08%,最大相对误差为0.89%;实验对比采用BP神经网络预测模型和卡尔曼滤波、GM(1,1)预测模型对交通流的预测,BP神经网络预测模型的误差指标大大减小,拟合度大大提高,有较好的准确性和可行性,能较准确地反映交通流真实情况。而经过小波去噪与BP神经网络结合的预测模型提高了预测精度,为交通流的实时动态预警提供了更加准确真实的情况。

关键词:短时交通流预测;小波变换;去噪;BP神经网络

中图分类号:U491.14

文献标识码:A

文章编号:1673-629X(2020)01-0135-05

doi:10.3969/j.issn.1673-629X.2020.01.024

Short-term Traffic Flow Prediction Based on Wavelet and Neural Network

LI Pei-yu

(School of Information Engineering, Chang'an University, Xi'an 710064, China)

Abstract: Aiming at the instability and complexity of actual traffic flow changes, it is a research hotspot in the field of intelligent transportation to apply traffic flow prediction model to obtain more accurate traffic flow information. We propose a prediction model based on wavelet analysis combined with neural network, whose main idea is to smooth the noise reduction of the original traffic flow data by wavelet multi-resolution analysis and Mallat algorithm. The db10 wavelet and soft threshold denoising function in the process are used to make the traffic flow curve more smooth and stable, and more realistically reflect the traffic flow. The three-layer BP neural network with activation function as Tan-Sigmoid, training function as trainlm and the number of neuron nodes in each layer as 1-12-1 is adopted to train the traffic flow data after denoising. The trained prediction model is used to predict the actual traffic flow information, and finally the accurate traffic flow information is obtained. The experiment shows that the average relative error of the prediction obtained by wavelet analysis combined with BP neural network is 0.03%, the maximum relative error is 0.39, and the fitness (EC) is 0.96. The average relative error of the prediction obtained by using BP neural network prediction model to predict traffic flow data is 0.08%, and the maximum relative error is 0.89%. The experimental comparison uses BP neural network prediction model and Kalman filter, GM(1,1) prediction model for traffic flow prediction. BP neural network prediction model has greatly reduced the error index, greatly improved the fitting degree, with better accuracy and feasibility, and can accurately reflect the real situation of traffic flow. The prediction model combined with wavelet denoising and BP neural network improves the prediction accuracy and provides a more accurate and true situation for the real-time dynamic warning of traffic flow.

Key words: short-term traffic flow prediction; wavelet transform; denoising; BP neural network

0 引言

交通流量是短时交通流状态的基本参数之一,因此交通流量的异常变化是交通诱导的重要参考因素。城市路网的交通流状态识别需要准确和实时的交通流预测,才能更好地指导智能交通、缓解交通拥堵、加快智慧城市的建设。

针对城市道路短时交通流动态预测,国内外学者也做了许多相关的研究。研究方法大体可以分为以下四类:第一类是针对交通参数的方法,诸如回归预测和时间序列预测^[1-3];第二类是基于混沌理论^[4-5]的一些预测方法;第三类是利用人工神经网络^[6-13]训练学习的预测方法;第四类是组合理论^[14-17]方法,将各模型的优点有机结合在一起,以达到更高效准确的预测结果。近年来,各种预测模型与小波理论的组合被相继提出,如窦慧丽等提出的基于小波分析和 ARIMA 模型的交通流预测^[18],王川等提出的基于小波分析与隐马尔可夫模型的短时交通流预测^[19]等。

短时交通流具有时变性、非线性与周期稳定性,受实际环境中的诸多因素干扰,导致实际采样的交通流参数数据不准确,从而影响短时交通流的预测结果。

文中提出的小波理论和 BP 神经网络结合的短时交通流预测组合模型,首先对实际采样的原始交通流数据进行小波消噪处理,然后采用 BP 神经网络模型对短时交通流进行预测,有效提高了预测精度。

1 基于小波分析的交通数据消噪算法

1.1 小波多分辨率分析与 Mallat 算法

20 世纪 80 年代后期,小波变换被提出。小波变换是信号在时频和频域同时进行多尺度联合分析的重要工具。小波分析中一个重要的概念是多分辨率分析^[20-21],即由粗到细的逐级分析,将函数的多分辨率空间分解与小波变换建立联系。一个函数空间 $L^2(R)$ 的多分辨率分析是由一系列闭子空间序列 $\{V_j\}_{j \in Z}$ 嵌套而成,函数空间平方可积。

设 $\{V_j\}_{j \in Z}$ 是由尺度函数 $\varphi(t)$ 生成的多分辨率分析,并有尺度方程:

$$\varphi(x) = \sqrt{2} \sum_{k \in Z} h_k \varphi(2x - k) \tag{1}$$

其中, $h_k = \sqrt{2} \int_{-\infty}^{+\infty} \varphi(x) \overline{\varphi(2x - k)} dx$ 。

小波函数定义为:

$$\varphi(x) = \sqrt{2} \sum_{k \in Z} g_k \varphi(2x - k) \tag{2}$$

其中, $g_k = (-1)^k h_{1-k}$ 。

$\{\varphi_{jk}(x) = 2^{j/2} \varphi(2x - k)\}_{k \in Z}$ 是 V_j 的标准正交基, $\{\psi_{jk}(x) = 2^{j/2} \psi(2x - k)\}_{k \in Z}$ 是 W_j 的标准正交基, $\{\psi_{jk}(x)\}_{k \in Z}$ 是 $L^2(R)$ 的标准正交基。并且有 $V_{j+1} = V_j$

$$\oplus W_j, V_j \perp W_j, L^2(R) = \bigoplus_{j \in Z} W_j。$$

假设 f 是要处理的实际信号,可看作 $f \in L^2(R)$,测得的信号为 f_i ,设 $f_i \in V_j$ 。由于 $\{\psi_{jk}(x)\}_{k \in Z}$ 是 V_j 的标准正交基,故有:

$$f_j(x) = \sum_{k \in Z} c_{jk} \varphi_{jk}(x) \tag{3}$$

用 φ_{jk} 与上式两端作内积,得

$$c_{jk} = \langle f, \varphi_{jk} \rangle \tag{4}$$

由于 $V_j = V_{j-1} \oplus W_{j-1}$,且 $V_{j-1} \perp W_{j-1}$,所以 $\{\varphi_{j-1,k}(x)\}_{k \in Z} \cup \{\psi_{j-1,k}(x)\}_{k \in Z}$ 也是 V_j 的标准正交基,故有:

$$f_j(x) = \sum_{k \in Z} c_{j-1,k} \varphi_{j-1,k}(x) + \sum_{k \in Z} d_{j-1,k} \psi_{j-1,k}(x) \tag{5}$$

再分别用 $\varphi_{j-1,k}$ 和 $\psi_{j-1,k}$ 与上式两端作内积,得:

$$c_{j-1,k} = \langle f_j, \varphi_{j-1,k} \rangle \tag{6}$$

及

$$d_{j-1,k} = \langle f_j, \psi_{j-1,k} \rangle \tag{7}$$

将尺度方程 1 写成一般形式:

$$\varphi_{j-1,k}(x) = \sum_{n \in Z} h_{n-2k} \varphi_n(x) \tag{8}$$

将式 8 代入式 6 得:

$$c_{j-1,k}(x) = \sum_{n \in Z} \bar{h}_{n-2k} c_n \tag{9}$$

类似的,将式 2 写成一般形式:

$$\varphi_{j-1,k}(x) = \sum_{n \in Z} g_{n-2k} \varphi_n(x) \tag{10}$$

代入式 7,并利用式 4,可得:

$$d_{j-1,k} = \sum_{n \in Z} \bar{g}_{n-2k} c_{jn} \tag{11}$$

式 9 和式 11 就是著名的 Mallat 分解算法。相反过程,由式 5 求出式 3,将两尺度方程的一般形式,即式 8 和式 10,代入式 5,得:

$$f_j(x) = \sum_{k \in Z} c_{j-1,k} \sum_{n \in Z} h_{n-2k} \varphi_n(x) + \sum_{k \in Z} d_{j-1,k} \sum_{n \in Z} g_{n-2k} \varphi_n(x) \tag{12}$$

通常在应用时有 h_k 非零,设 h_0, h_1, \dots, h_{M-1} 非零,其余 h_k 都为零。由 $g_k = (-1)^k \bar{h}_{1-k}$ 得, $g_{2-M}, g_{3-M}, \dots, g_0, g_1$ 非零,其余 g_k 都为零。

Mallat 算法可以变为如下形式:

分解公式:

$$\begin{cases} c_{j-1,k} = \sum_{n=2k}^{2k+M-1} \bar{h}_{n-2k} c_{jn} \\ d_{j-1,k} = \sum_{n=2k+2-M}^{2k+1} \bar{g}_{n-2k} c_{jn} \end{cases} \tag{13}$$

重构公式:

$$c_{jn} = \sum_{k=\lceil \frac{n-M+1}{2} \rceil}^{\lfloor \frac{n+1}{2} \rfloor} h_{n-2k} c_{j-1,k} + \sum_{k=\lfloor \frac{n+1}{2} \rfloor}^{\lfloor \frac{n-M+1}{2} \rfloor} g_{n-2k} d_{j-1,k} \tag{14}$$

1.2 小波阈值去噪原理

小波阈值去噪的原理是将原始信号经小波分解

后,信号的小波系数幅值要大于噪声的系数幅值。通过选取一个合适的阈值,保留大于阈值的小波系数,小于阈值的系数置零,将有效信号与噪声分离。

小波变换具有很强的去相关性,可以将信号的自身能量集中。应用小波阈值去噪的基本过程为:

(1)分解:选取合适的小波基后,对信号进行多层小波分解;

(2)阈值处理:分解后选取一个阈值,用阈值对各层系数进行处理;

(3)重建:用阈值处理后的小波系数重构原始信号。

小波阈值去噪过程中,最重要一环即是对小波系数进行处理。应用不同的阈值函数对小波系数的处理方式也不同。常用的阈值函数有硬阈值和软阈值函数。

硬阈值函数:

$$\eta(\omega) = \begin{cases} \omega, & |\omega| \geq T \\ 0, & |\omega| < T \end{cases} \quad (15)$$

软阈值函数:

$$\eta(\omega) = \begin{cases} \omega - \text{sgn}(\omega), & |\omega| \geq T \\ 0, & |\omega| < T \end{cases} \quad (16)$$

其中, ω 为原小波系数; $\eta(\omega)$ 为阈值化后的小波系数; T 为阈值。

由公式可看出,重构信号采用硬阈值函数处理更加准确,但伴有局部振荡。而重构信号采用软阈值处理后误差变大,但得到的信号平滑性较好。

1.3 基于小波分析的交通数据去噪实验

多分辨率分析也称多尺度分析。原始交通流数据分解几次即为其分解尺度。当近似信号部分和细节部分分解到图形平滑稳定时分解结束。

实验采用一天的交通流量数据,采用 db10、db5、db1 小波函数,利用 Mallat 算法进行尺度 N 为 4 层的金字塔式分解,分解前后曲线如图 1 所示。




图 1 利用 db10 进行小波分解后近似部分和细节部分

通过实验对比,采用 db10 小波函数分解得到的第 4 层细节部分比采用 db5、db1 函数分解得到的细节部分的曲线更加平滑,故实验采用 db10 小波作为母小波。

图 2 为原始交通数据,对其分解后的曲线进行重构;图 3 为单支重构后第一层近似部分 a_1 。可以发现,后者的曲线较为平滑。




图 2 原始数据信号曲线




图 3 单支重构后第一层近似部分 a_1

采用 FFT 和小波分析方法分别对原始交通数据进行阈值去噪处理,并分别采用硬阈值函数和软阈值函数处理后进行对比,实验采用 db10 作为小波函数,分解尺度值为 4。实验结果如表 1 所示。

表 1 小波去噪与傅里叶变换去噪对比结果分析

指标	rigrsure	sqtwolog	FFT
SNR	57.56	53.42	44.19
RMSE	13.37	16.44	26.07

其中 rigrsure 为硬阈值, sqtwolog 为软阈值。使用信噪比 (SNR) 和均方根误差 (RMSE) 作为评判指标。SNR 越高, RMSE 越小, 去噪后的交通数据就越接近原始交通数据, 去噪的结果也越好。通过比较可以发现, 采用小波软阈值去噪方法对交通数据进行去噪处理的效果更佳。

2 BP 神经网络交通流预测模型

神经网络的一个重要应用是进行预测。BP 神经网络是一个基于 Widrow-Hoff 学习规则的正向传递工作信号反向传递误差信号的多层网络。一般由输入层、输出层和隐含层(一层或若干层)构成。BP 神经网络采用多层感知器的设计解决了单层感知器不能很好解决的线性不可分问题。

BP 神经网络的正向传递子过程描述如下:

$$S_j = \sum_{i=0}^{m-1} w_{ij}x_i + b_j \quad (17)$$

$$x_j = f(S_j) \tag{18}$$

其中, w_{ij} 为节点 i 和 j 之间的权值; b_j 为节点 j 的阈值; x_j 为每个节点的输出值; f 为激活函数。

而误差反向传递子过程是基于 Widrow-Hoff 学习规则, 通过沿着相对误差平方和的最速下降方向, 不断调整网络的权值和阈值, 来减少实际输出和期望输出的误差。

一个用于预测的 BP 神经网络模型需要确定输入、输出、隐含层的节点数, 激活函数以及训练函数。

BP 神经网络的激活函数一般使用相比线性函数更加光滑、可微的 Sigmoid 函数。实验中隐含层神经元的激活函数设置为 Sigmoid 函数中输出值包含负值的 Tan-Sigmoid 函数。

确定好网络中各层的激活函数后, 需要确定网络的训练函数, 通过不断对网络进行训练, 将得到的误差作对比, 选择出使得误差较小的训练函数, 从而最终确定最佳节点数目。

选择 `traingd` 作为训练函数时, 即使用梯度下降算法进行训练后, 平均误差为 0.021 4, 训练次数为 1 000, 但未达到训练效果; 选择 `traingdx` 作为训练函数, 即使用动量及自适应学习率的梯度递减算法进行训练后, 平均误差为 0.019 9, 训练次数为 140, 达到了训练目标; 选择 `trainlm` 作为训练函数, 即使用 L-M 算法进行训练后, 平均误差为 0.019 2, 训练次数为 5, 最终也达到了训练目标。

由于交通流量数据只有一类, 最终确定了隐含层为一层, 各层神经元节点数为 1-12-1, 训练函数为 `trainlm` 的 BP 神经网络结构, 并使用训练好的网络对交通量数据进行预测。

3 应用实例

采用文中提出的预测方法, 对西安市某路段时间

间隔为 5 min 的某一天的交通流量进行预测。图 4 从上到下分别展示了对原始交通流数据采用 BP 神经网络预测后的结果, 将原始数据经过小波去噪, 再采用 BP 神经网络模型得到的预测结果、采用卡尔曼滤波预测模型^[22-23]和 GM(1,1) 预测模型^[24-25]对相同的交通流进行预测得到的结果。

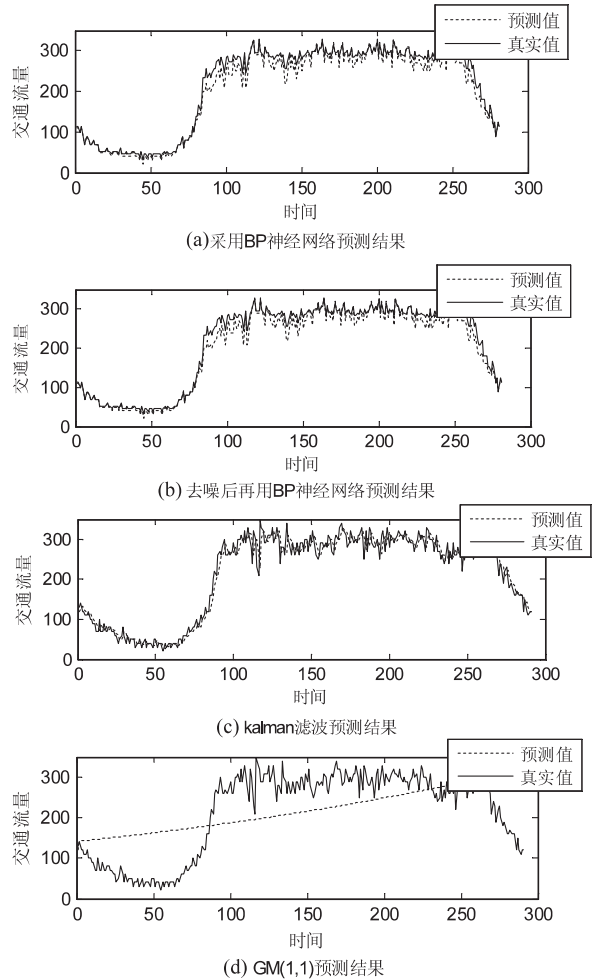


图 4 三种预测模型的预测结果

对这三种预测模型的误差参数分析如表 2 所示。

表 2 三种预测模型各误差参数

模型	mreer/%	marerr/%	mxarerr/%	nnrerr/%	EC	MSE
BP 神经网络	0.03	0.08	0.89	1.98	0.96	349.78
基于小波变换的 BP 神经网络	0.03	0.03	0.39	1.56	0.96	241.02
Kalman 滤波	0.04	0.11	0.69	2.61	0.95	525.10
GM(1,1)	0.06	0.26	0.99	6.22	0.89	48.05

误差指标分别为: 相对误差 (mreer)、平均绝对相对误差 (marerr)、最大绝对相对误差 (mxarerr)、相对误差平方和均值平方根 (nnrerr)、均等系数 (EC) 和均方误差 (MSE)。

从实验结果对比可以看出, 基于小波变换的 BP 神经网络预测方法和卡尔曼滤波模型预测拟合度都高于 0.90, 而 GM(1,1) 预测方法的拟合度低于 0.90。

经分析, GM(1,1) 模型适用于具有指数增长的序列, 即增长率稳定在一个值附近波动, 对于非线性的短时交通流量预测不能达到较为理想的预测精度。再比较基于小波变换的 BP 神经网络预测模型和卡尔曼滤波预测模型, 卡尔曼滤波模型的平均绝对相对误差 (marerr) 和相对误差平方和均值平方根 (nnrerr) 明显大于基于小波变换的 BP 神经网络预测模型。因此,

结合小波去噪的BP神经网络预测模型运用到短时交通流量方面展现出了较好的准确性和可行性。

4 结束语

考虑到交通流数据采集过程中受实际环境影响等使得交通流预测精度不高,结合小波分析的消噪原理,建立基于BP神经网络的短时交通流预测模型。实验结果表明,小波分析和BP神经网络结合的交通流预测模型具有较高的预测精度,为后续交通拥堵动态预警的实时预测提供了一种新思路。

参考文献:

- [1] 康军,段宗涛,唐蕾,等.高斯过程回归短时交通流预测方法[J].交通运输系统工程与信息,2015,15(4):51-56.
- [2] 刘艳忠,邵小健,李旭宏.基于Lagrange支持向量回归机的短时交通流量预测模型的研究[J].交通与计算机,2007,25(5):46-49.
- [3] 张晓利,陆化普.非参数回归方法在短时交通流预测中的应用[J].清华大学学报:自然科学版,2009,49(9):1471-1475.
- [4] 贾显超,陈旭梅,弓晋丽,等.基于混沌理论的短期交通流量多步预测[J].交通信息与安全,2013,31(6):27-32.
- [5] 宋高,韩印,易若晨.基于混沌理论的短时交通流量预测[J].交通与运输,2010(12):1-3.
- [6] 李会超,李鸿,张博.基于遗传算法优化小波神经网络的短时交通流量预测[J].计算机应用与软件,2018,35(7):148-152.
- [7] 王秋平,舒勤,黄宏光.含有误差校正的小波神经网络交通流量预测[J].计算机测量与控制,2016,24(2):168-170.
- [8] 赖锦辉,梁松.基于ACS优化BP神经网络的交通流量短时预测方法[J].计算机工程与应用,2014,50(10):244-248.
- [9] 侯越.基于改进T-S模糊神经网络的交通流量预测[J].计算机科学与探索,2014,8(1):121-126.
- [10] 高述涛.CS算法优化BP神经网络的短时交通流量预测[J].计算机工程与应用,2013,49(9):106-109.
- [11] 张琛,徐国丽.基于云遗传的RBF神经网络的交通流量预测[J].计算机工程与应用,2014,50(16):216-220.
- [12] 于振洋.小波消噪的神经网络短时交通流量预测模型[J].计算机仿真,2012,29(9):360-363.
- [13] 万李,杨杰.小波神经网络在短时交通流量预测中的应用[J].计算机仿真,2012,29(9):352-355.
- [14] 聂佩林,余志,何兆成.基于约束卡尔曼滤波的短时交通流量组合预测模型[J].交通运输工程学报,2008,8(5):86-90.
- [15] 宋曰聪,胡伟,张涛.基于遗传算法的交通流量组合预测研究[J].微计算机信息,2007,23(29):55-56.
- [16] 姚智胜,邵春福,熊志华.基于小波包和最小二乘支持向量机的短时交通流组合预测方法研究[J].中国管理科学,2007,15(1):64-68.
- [17] 李颖宏,刘乐敏,王玉全.基于组合预测模型的短时交通流预测[J].交通运输系统工程与信息,2013,13(2):34-41.
- [18] 窦慧丽,刘好德,吴志周,等.基于小波分析和ARIMA模型的交通流预测方法[J].同济大学学报:自然科学版,2009,37(4):486-489.
- [19] 王川,张宝文.基于小波分析与隐马尔科夫模型的短时交通流预测[J].交通节能与环保,2018,14(1):43-47.
- [20] 程颖,陈艳艳,刘莹,等.城市交通排放高分辨率分析方法研究——北京实证[J].交通运输系统工程与信息,2018,18(2):236-244.
- [21] 何锡玉,蔡夕方,景嘉洲.小波变换分析降水时间序列的多分辨率特性研究[J].计算机应用,2013,33(S1):331-334.
- [22] 袁磊,梁丁文,蔡之华,等.基于正交差分演化无迹卡尔曼滤波的短时交通流量预测算法[J].计算机应用,2015,35(11):3151-3156.
- [23] 梅朵,郑黎黎,刘春晓,王秀芹.基于混合算法优化SVM的短时交通流预测[J].计算机技术与发展,2017,27(11):92-95,100.
- [24] 吴宝春,郑蕊蕊,李敏,等.基于遗传灰色GM(1,1, ρ)模型的短时交通流量预测[J].电子设计工程,2012,20(13):165-167.
- [25] 郭欢,肖新平,Jeffrey Forrest.基于GM(1,1| τ , r)模型的城市道路短时交通流预测[J].交通运输系统工程与信息,2013,13(6):60-66.