

基于 ANFIS 混合模型的短时交通流预测^①



颜秉洋, 唐敏佳, 周长庚, 李银萍

(山东建筑大学 信息与电气工程学院, 济南 250101)

通讯作者: 颜秉洋, E-mail: bingyang.yan@foxmail.com

摘要: 城市短时交通流预测可以帮助人们选择出行最优路线, 提高出行效率, 其研究在交通拥堵日益严重的今天十分必要. 受天气等多种因素影响, 短时交通流的精确预测比较困难, 为改善短时交通流预测的精度, 本文提出了一种基于自适应模糊推理系统 (ANFIS) 的混合模型. 该混合模型用周期性知识模型及残差数据驱动 ANFIS 模型集成得到. 为验证所提出的混合模型的性能, 与倒向传播神经网络 (BPNN) 模型和普通 ANFIS 模型进行对比. 实验结果证明混合模型在交通流预测方面有更好的适用性和准确度.

关键词: 交通流预测; 周期性提取; 自适应模糊推理系统 (ANFIS); 反向传播算法; 最小二乘法

引用格式: 颜秉洋, 唐敏佳, 周长庚, 李银萍. 基于 ANFIS 混合模型的短时交通流预测. 计算机系统应用, 2019, 28(6): 247-253. <http://www.c-s-a.org.cn/1003-3254/6906.html>

Short-Term Traffic Flow Prediction Based on ANFIS Hybrid Model

YAN Bing-Yang, TANG Min-Jia, ZHOU Chang-Geng, LI Yin-Ping

(School of Information and Electrical Engineering, Shandong Jianzhu University, Jinan 250101, China)

Abstract: Urban short-term traffic flow forecasting can help people choose the optimal route for travel and improve travel efficiency, which is necessary because the traffic congestion increasingly serious today. It is difficult to predict short-term traffic flow accurately because there are various factors can influence short-term traffic flow such as weather. To improve the accuracy of short-term traffic flow prediction, this study proposes a hybrid model based on Adaptive Neuro-Fuzzy Inference System (ANFIS). The hybrid model is combined with the periodicity knowledge model and the ANFIS model which has been driven by residual data. To verify the performance of the proposed hybrid model, it is compared with the Backward Propagating Neural Network (BPNN) model and the normal ANFIS model. The experimental results show that the hybrid model has better applicability and accuracy in traffic flow prediction.

Key words: traffic flow prediction; periodic extraction; Adaptive Neuro-Fuzzy Inference System (ANFIS); back propagation algorithm; least squares

随着社会的高速发展, 越来越多的车辆出现在人们的日常生活中, 给人们带来一定程度出行便利的同时, 也导致了城市交通的日益拥堵. 城市短时交通流预测作为城市计算^[1-3]中的一个重要研究方向, 由城市交通大数据驱动, 可以大大提高生活效率, 提升城市的智能化水平.

短时交通流预测的研究已经发展了很多年, 从统计学方法到神经网络方法和模糊系统的方法, 交通流预测越来越精确、适用. 统计学方法是通过对历史交通流数据进行线性回归处理来进行交通流预测的. Sun 等^[4]利用局部线性回归模型对从休斯顿采集到的交通流数据进行短时预测. Dang 等^[5]采用多元线性自

① 收稿时间: 2018-11-28; 修改时间: 2018-12-18; 采用时间: 2018-12-28; csa 在线出版时间: 2019-05-25

回归模型进行交通流预测. Williams 等^[6,7]根据季节性自回归移动平均 (ARIMA) 算法建模以便交通流预测. Tan 等^[8]将 ARIMA 模型和支持向量机 (SVM) 模型结合组成混合模型来预测交通流. 作为样本学习的优势方法, 支持向量机在交通流预测中也有很多应用. 朱征宇等^[9]把卡尔曼滤波和 SVM 结合起来, 发挥两者的优势来共同预测短时交通流. 文献^[10]中提出了一种将支持向量回归 (SVR) 模型用到交通流预测上的方法, 进而应用到动态导航系统上. 文献^[11]运用 SVR 和连续蚁群算法对城市间交通流量进行了预测. 神经网络方法由于其高效的学习能力, 在交通流预测中得到了越来越多的应用. Kim 等人^[12]结合混合高斯和神经网络方法建模, 结合道路和环境因素进行交通流预测. 文献^[13]中通过利用深信度神经网络 (DBN) 的方法建模来预测交通流. 文献^[14]中将卷积神经网络 (CNN) 和 SVR 结合起来组成预测交通流的混合模型. 但上述方法其模型不具有可解释性, 近年来以规则刻划的模糊方法在交通流预测中得到发展, 特别是和神经网络有机结合的模糊神经网络方法. Yin 等^[15]结合了模糊系统和神经网络提出一种模糊神经模型来预测街道交通流. Quek 等^[16]利用模糊神经网络模型来预测交通流, 这种模型结合了模糊推理系统和神经网络, 互补的利用两者的特点来预测. Chan 等^[17]根据模糊神经网络和 Taguchi 方法相对高精度的预测道路交通流数据.

上述研究中采用了各种各样的模型来预测交通流, 可以看出对于交通流特征学习的改进方法层出不穷, 但是关于交通流数据的固有特性却一直未能很好的利用. 通过观察交通流的数据, 可以发现一些关于交通流周期性的先验知识, 如不同工作日的交通流具有相似的趋势, 即交通流量具有周期性模式. 交通流的周期性是城市交通数据的重要特征, 可以很好的反应出城市交通流量的特点, 利用这种先验知识训练交通流预测模型, 可以提高模型的预测性能. 本文将交通流的周期性先验知识提取出来, 获得交通流残差数据, 进而通过残差数据训练混合模型得到交通流预测值, 通过跟 BPNN 模型和普通 ANFIS 模型进行对比, 验证混合模型的优越性. 本方法利用 ANFIS 结合交通流周期性的混合模型来预测短时交通流, 即可以充分利用交通流的特性, 也可以发挥 ANFIS 适应交通流非线性数据的特点, 可以准确的预测城市短时交通流量. 该研究基于实际城市交通流数据来验证混合模型的泛化能力, 为

接下来在其他应用方面的研究提供全新的思路.

1 方法介绍

为了证明混合模型在交通流预测中的优越性, 本文用了混合模型跟 BPNN 模型和普通 ANFIS 模型相比较, ANFIS 模型和 BPNN 模型具体内容如下:

1.1 ANFIS 模型

自适应模糊推理系统 (ANFIS) 是由 Jang^[18]首次提出的, 它有机结合了模糊推理系统 (FIS) 和神经网络 (NN), 利用神经网络的框架, 通过自适应的混合算法在数据中提取模糊规则, 进而调整前件参数和后件参数, 获取最优解, 既发挥了 FIS 和 NN 的优点, 又弥补了彼此的不足, 增强了 FIS 的学习能力. 假定采用规则库:

$$\begin{cases} R(s) : x_1 = D_1^s, x_2 = D_2^s, \dots, \\ x_n = D_n^s \rightarrow y_s(x) = c_0^s + \sum_{i=1}^n c_i^s x_i \end{cases} \quad (1)$$

其中, D_j^s 是输入变量 x_j 的模糊集, c_i^s ($i = 0, 1, \dots, n$) 是模糊规则 $R(s)$ 的后件部分.

对应该规则库的 ANFIS 结构如图 1 所示. 该 ANFIS 一共有 5 层, 第一层为模糊化层, 将输入数据 x_1, x_2, \dots, x_n 经过隶属函数处理输出对应模糊集的隶属度, 第二层实现前件部分模糊集的运算, 输出为每个规则的激励强度, 第三层将各个激励强度归一化, 第四层计算每个模糊规则的输出, 第五层计算 ANFIS 的输出.

上述 ANFIS 输入输出关系可以描述为:

$$\hat{y}(x) = \sum_{s=1}^S \bar{f}_s(x) y_s(x) = \frac{\sum_{s=1}^S f_s(x) y_s(x)}{\sum_{s=1}^S f_s(x)} \quad (2)$$

其中, $f_s(x)$ 和 $\bar{f}_s(x)$ 代表激励强度和归一化后的激励强度, 其计算公式为:

$$f_s(x) = \prod_{j=1}^n \mu_{D_j^s}(x_j) \quad (3)$$

$$\bar{f}_s(x) = \frac{f_s(x)}{\sum_{s=1}^S f_s(x)} \quad (4)$$

ANFIS 模型的构建过程, 首先确定输入数据的模糊划分和模糊集合类型, 然后采用反向传播算法和线性最小二乘法的混合算法进行前件参数和后件参数的训练, 前件参数采用反向传播算法进行训练, 后件参数运用最小二乘法进行训练. 输入数据沿 ANFIS 网络运

算到第四层, 固定前件参数, 用最小二乘法训练后件参数, 信号正向传递至输出层, 利用反向传播算法训练前件参数, 循环迭代至全局最优。

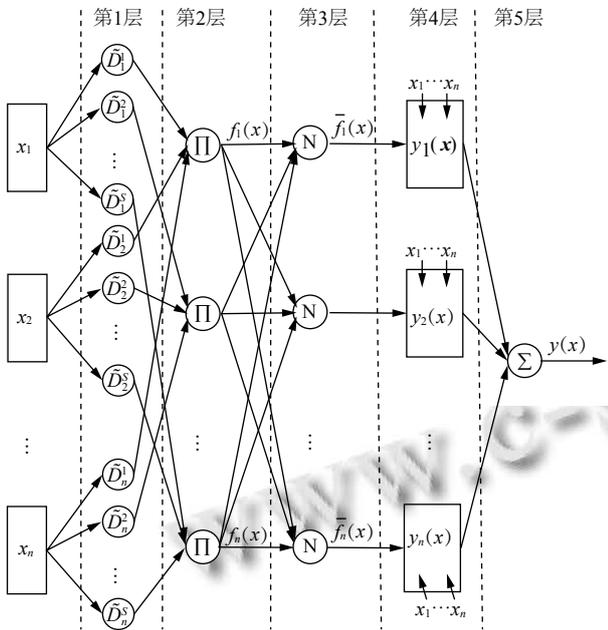


图1 ANFIS 结构图

1.2 BPNN 模型

BPNN 是迄今应用范围最广泛的人工神经网络之一, 理论上具有无限逼近的能力, 在 BPNN 中, 通常采用反向传播算法或其变种来确定整个网络的权重. 在本文中考虑一个具有 L 个隐藏层的 BPNN, 具体结构如图 2 所示。

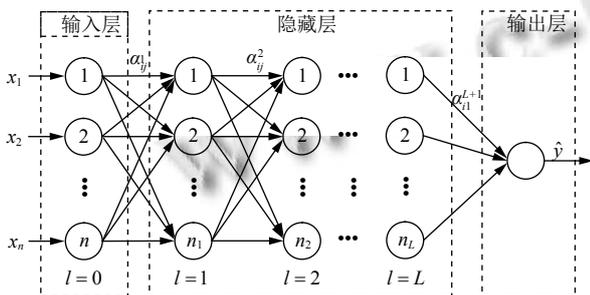


图2 BPNN 结构图

BPNN 的输入输出关系可以表示为:

$$\hat{y}(x) = f \left(\sum_{s=1}^{n_L} \alpha_{s1}^{L+1} \dots f \left(\sum_{j=1}^{n_1} \alpha_{jL}^2 f \left(\sum_{i=1}^n \alpha_{ij}^1 x_i \right) \right) \right) \quad (5)$$

其中, $f()$ 为激活函数, α_{ij}^l 为连接第 l 层第 i 个神经元和第

$l+1$ 层第 j 个神经元的权重。

BP 算法会通过最小化平方差公式来获得最优值或者次优值, 如下式所示:

$$E(k) = (\hat{y}(x^{(k)}) - y^{(k)})^2 \quad (6)$$

其中, $\hat{y}(x^{(k)})$ 是 BPNN 模型中输入为 $x^{(k)}$ 的预测值。

在 BPNN 算法中, 连接权重 α_{ij}^l 的更新规则如下:

$$\alpha_{ij}^l(k+1) = \alpha_{ij}^l(k) - \varepsilon \frac{\partial E(k)}{\partial \alpha_{ij}^l} \quad (7)$$

其中, ε 是学习率, 在更新规则中, 最重要的是计算梯度 $\frac{\partial E(k)}{\partial \alpha_{ij}^l}$, 可以通过预测值和实际值误差的反向传播完成。

2 交通流预测混合模型

2.1 混合模型结构

结合上述 ANFIS 模型和周期性提取方法, 本文提出了一个基于 ANFIS 混合模型的交通流预测模型. 结构如图 3 所示。

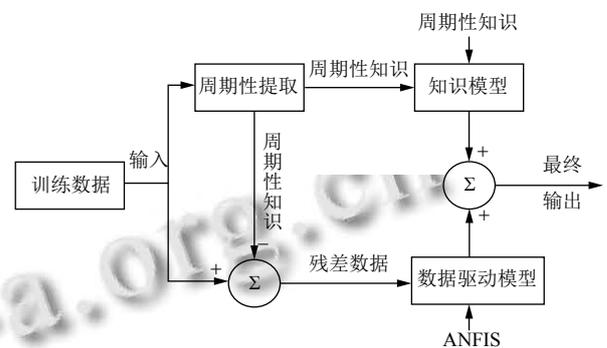


图3 交通流 ANFIS 模型

模型训练的步骤如下:

- 1) 提取交通流数据周期性信息, 从交通数据中移除提取的周期性信息, 获得交通流残差数据。
- 2) 将交通流残差数据输入混合模型, 利用混合训练方法训练前件、后件参数以取得最优结果。
- 3) 将训练完的交通流残差数据和交通流周期性信息重新结合, 得到最优交通流预测值。

2.2 周期性知识模型构建

假设有 M 天历史交通流数据 $Y = \{Y_1, Y_2, \dots, Y_M\}$, 每天有 T 个检测点, 将交通流数据表示为:

$$\begin{cases} Y_1 = [y_1(1), y_1(2), \dots, y_1(T)] \\ \vdots \\ Y_M = [y_M(1), y_M(2), \dots, y_M(T)] \end{cases} \quad (8)$$

对于每天一个周期的周期性信息,提取的方法为:

$$\bar{Y}_{Ave} = \left[\frac{1}{M} \sum_{z=1}^M y_z(1), \frac{1}{M} \sum_{z=1}^M y_z(2), \dots, \frac{1}{M} \sum_{z=1}^M y_z(T) \right] \quad (9)$$

然后,残差数据可以表示为:

$$Y_{Res} = \{Y_1 - \bar{Y}_{Ave}, Y_2 - \bar{Y}_{Ave}, \dots, Y_M - \bar{Y}_{Ave}\} \quad (10)$$

3 交通流预测实验

这个部分主要介绍利用混合模型进行交通流预测实验的细节和过程.

3.1 实验数据

本文选用2009年10月1号到2009年11月30号的交通流数据用来训练和测试,实验数据来源于PeMS(美国加州性能测量系统),数据通过探测器每30秒收集一次.本文用10分钟、15分钟的时间间隔进行交通流预测实验,用来验证模型的性能.初始数据如图4所示.

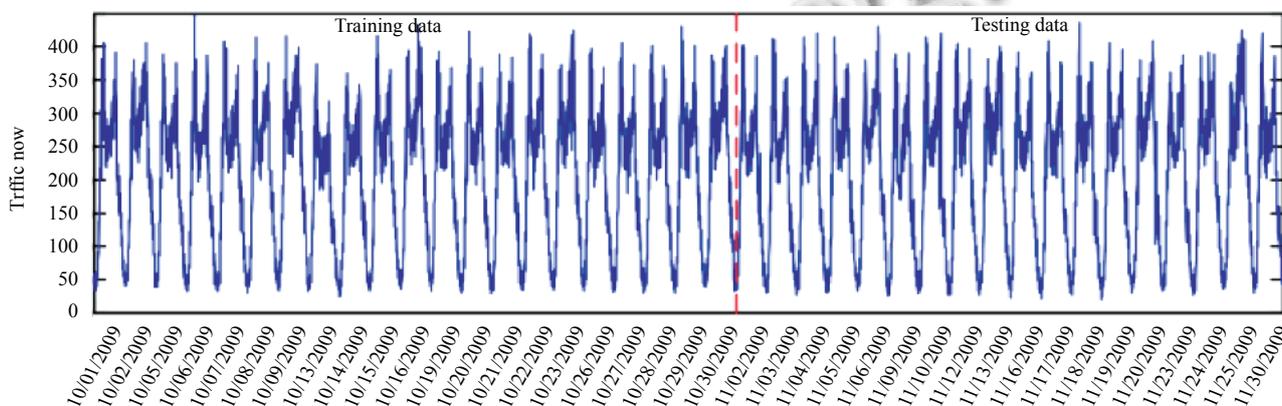


图4 原始交通流数据图

3.2 性能指标

模型的预测性能用均方根误差 (RMSE)、平均绝对误差 (MAE)、平均百分比误差 (APE) 三个指标来衡量,具体如下:

$$\begin{cases} RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N |\hat{y}(x^i) - y^{(i)}|^2}, \\ MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}(x^i) - y^{(i)}|, \\ APE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}(x^i) - y^{(i)}|}{|y^{(i)}|} \times 100\%, \end{cases} \quad (11)$$

其中, $\hat{y}(x^i)$ 和 $y^{(i)}$ 分别代表输入 x^i 的预测数据和实际数据, N 代表训练和测试的数据个数.

3.3 实验结果

3.3.1 交通流预测 (10 分钟间隔)

本文采用的交通流实验数据总共有39天,前21天的数据作为训练数据,余下18天的数据作为测试数据,交通流数据每天有144个10分钟间隔的数据点,

所以训练数据有 $21 \times 144 = 3024$ 个,测试数据有 $18 \times 144 = 2592$ 个,如图5(a)所示,周期性数据如图5(b)所示,去除周期性的残差数据如图5(c).

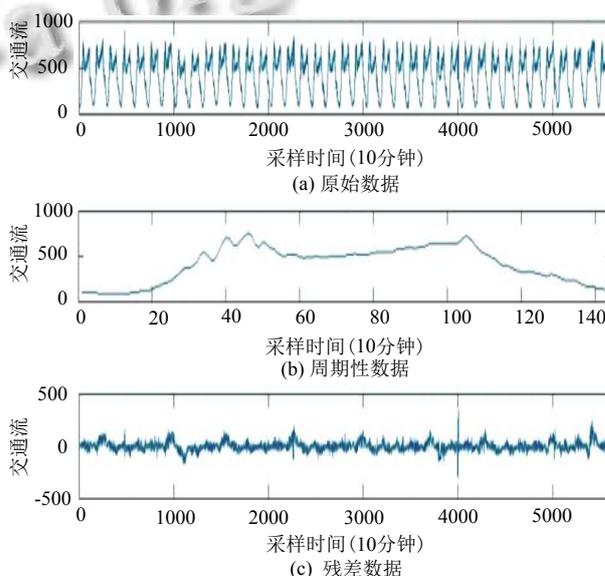


图5 交通流数据 (10 分钟间隔)

利用残差数据训练混合 ANFIS 模型, 预测结果 (10 分钟间隔) 如图 6 所示.

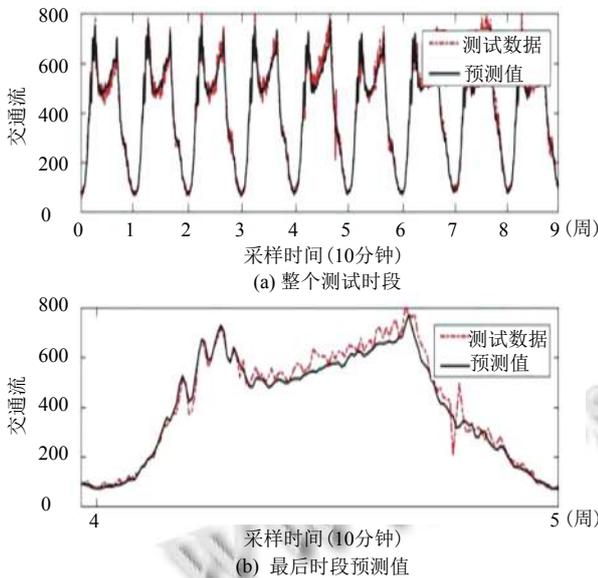


图 6 交通流预测结果 (10 分钟间隔)

混合模型和其他交通流预测模型的实验 (10 分钟间隔), 各指标对比如表 1 所示.

表 1 不同模型的指标对比 (10 分钟间隔)

	RMSE	MAE	APE
混合模型	34.8254	23.1315	7.4199
ANFIS	58.6331	41.5840	12.1623
BPNN	57.3032	44.9241	13.9744

3.3.2 交通流预测 (15 分钟间隔)

15 分钟间隔的交通流预测, 交通流训练数据有 2016 个点, 1728 个测试点, 原始数据如图 7(a) 所示, 周期性数据如图 7(b), 残差数据如图 7(c).

将残差数据用来训练本文提出的混合交通流预测模型, 预测结果如图 8 所示.

混合模型 15 分钟时间间隔的交通流预测与 ANFIS 模型和 BPNN 模型的预测指标对比如表 2 所示.

交通流数据和二次交通流预测实验的预测值散点图如图 9 所示.

3.4 实验结果分析

从上述两个不同时间间隔的交通流预测实验中可以得到以下结论:

1) RMSE、MAE、APE 三个性能衡量参数越小, 证明模型的预测性能越好. 从表 1 和表 2 中可以发现

本文提出的混合模型同 ANFIS 模型和 BPNN 模型相比表现是最好的, 充分表明交通流周期性的提取, 进而利用残差数据训练模型这一方法对与提高交通流预测精度的重要性. 预测准确率提升情况如表 3 所示.

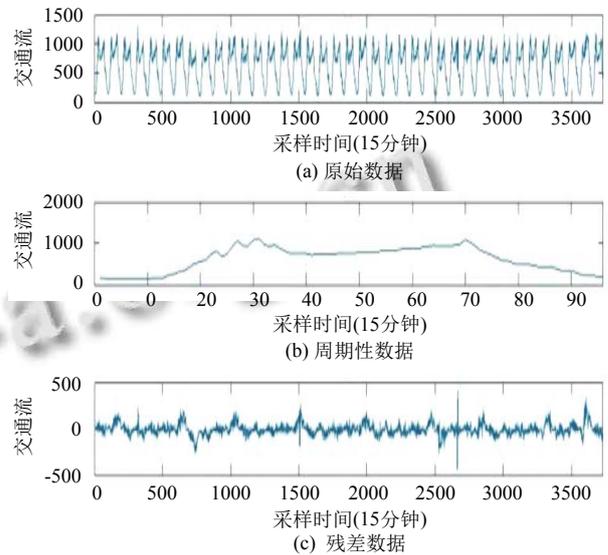


图 7 交通流数据 (15 分钟间隔)

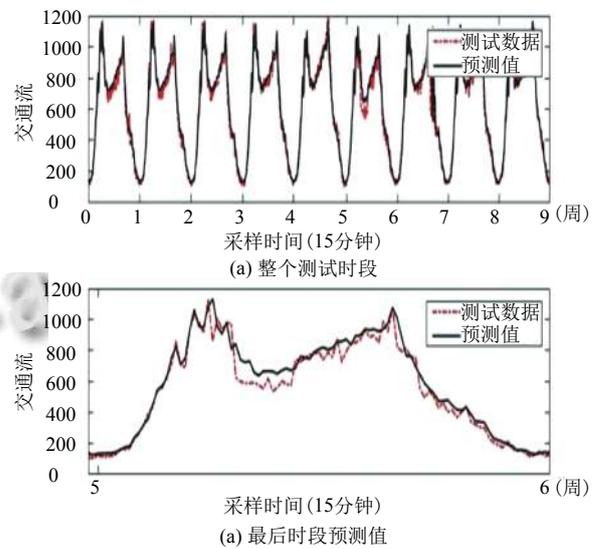


图 8 交通流预测结果 (15 分钟间隔)

表 2 不同模型的指标对比 (15 分钟间隔)

	RMSE	MAE	APE
混合模型	47.4759	32.5041	6.1310
ANFIS	72.6402	53.2395	10.1696
BPNN	75.7921	57.9482	11.6842

2) 图 9 为交通流数据和二次交通流预测实验的预测值之间的散点图. 图中可以看出交通流混合模型的

预测值和实际交通流数据有着很小的差别,反映了混合模型突出的预测准确度。

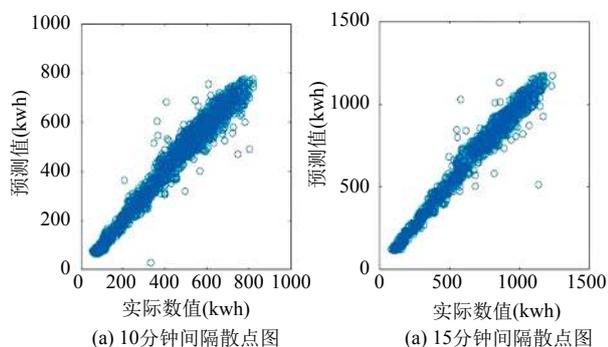


图9 交通流散点图

表3 交通流预测精度升降表(%)

	ANFIS	BPNN
10分钟	40.6	39.2
15分钟	34.6	37.4

4 结语

本文提出了一个基于 ANFIS 的混合交通流预测模型,提升了交通流预测的准确度,该模型提取了交通流的周期性,利用去除周期性数据的残差数据训练 ANFIS 模型,进而得到交通流预测值。本模型的理论贡献是将 ANFIS 模型和交通流周期性提取方法有机结合,根据交通流周期性这一固有特征和 ANFIS 模型对交通流数据非线性特点的匹配,组成 ANFIS 交通流预测混合模型。另一方面,该方法在交通流预测应用中的突出表现也在实验结果中得以验证,证明了该混合模型的有效性和优先性。

众所周知,很多数据如电力负荷、建筑能耗都有周期性特征的存在,混合模型的方法同样适合应用于这些有相似时间序列的预测方向上。随着大数据时代的不断发展,其他同样具有周期性特征的预测应用如大数据环境下的建筑能耗预测是本文下一步的研究方向。

参考文献

- Zheng Y, Capra L, Wolfson O, *et al.* Urban computing: concepts, methodologies, and applications. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2014, 5(3): 38.
- Zheng Y, Liu YC, Yuan J, *et al.* Urban computing with taxicabs. *Proceedings of the 13th International Conference on*

- Ubiquitous Computing. New York, NY, USA. 2011. 89–98.
- Li YX, Zheng Y, Zhang HC, *et al.* Traffic prediction in a bike-sharing system. *Proceedings of the 23rd Sigspatial International Conference on Advances in Geographic Information Systems*. New York, NY, USA. 2015. 33:1–33:10.
- Sun H, Liu HX. Short-term traffic forecasting using the local linear regression model. *Center for Traffic Simulation Studies*, 2002.
- Dang XC, Yan L. Traffic flow prediction based on multivariate linear AR model. *Computer Engineering*, 2012, 38(1): 84–86.
- Williams BM, Hoel LA. Modeling and forecasting vehicular traffic flow as a seasonal stochastic time series process. 1999.
- Williams BM, Hoel LA. Modeling and forecasting vehicular traffic flow as a seasonal ARIMA process: Theoretical basis and empirical results. *Journal of Transportation Engineering*, 2003, 129(6): 664–671. [doi: 10.1061/(ASCE)0733-947X(2003)129:6(664)]
- Tan MC, LI YJ, Xu JM. A hybrid ARIMA and SVM model for traffic flow prediction based on wavelet denoising. *Journal of Highway and Transportation Research and Development*, 2009, 26(7): 127–132, 138.
- 朱征宇, 刘琳, 崔明. 一种结合 SVM 与卡尔曼滤波的短时交通流预测模型. *计算机科学*, 2013, 40(10): 248–251, 278. [doi: 10.3969/j.issn.1002-137X.2013.10.052]
- Fu H, Xu LH. SVR prediction method of short-term traffic flow for dynamic navigation system. *Microcomputer Information*, 2009, 25(8-3): 208–210.
- Hong WC, Dong YC, Zheng FF, *et al.* Forecasting urban traffic flow by SVR with continuous ACO. *Applied Mathematical Modelling*, 2011, 35(3): 1282–1291. [doi: 10.1016/j.apm.2010.09.005]
- Oh SD, Kim YJ, Hong JS. Urban traffic flow prediction system using a multifactor pattern recognition model. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(5): 2744–2755. [doi: 10.1109/TITS.2015.2419614]
- Huang WH, Song GJ, Hong HK, *et al.* Deep architecture for traffic flow prediction: deep belief networks with multitask learning. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(5): 2191–2201. [doi: 10.1109/TITS.2014.2311123]
- 罗文慧, 董宝田, 王泽胜. 基于 CNN-SVR 混合深度学习模型的短时交通流预测. *交通运输系统工程与信息*, 2017, 17(5): 68–74.
- Yin HB, Wong SC, Xu JM, *et al.* Urban traffic flow prediction using a fuzzy-neural approach. *Transportation*

- Research Part C Emerging Technologies, 2002, 10(2): 85–98. [doi: [10.1016/S0968-090X\(01\)00004-3](https://doi.org/10.1016/S0968-090X(01)00004-3)]
- 16 Quek C, Pasquier M, Lim BBS. POP-TRAFFIC: a novel fuzzy neural approach to road traffic analysis and prediction. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(2): 133–146. [doi: [10.1109/TITS.2006.874712](https://doi.org/10.1109/TITS.2006.874712)]
- 17 Chan KY, Dillon TS. On-road sensor configuration design for traffic flow prediction using fuzzy neural networks and taguchi method. IEEE Transactions on Instrumentation & Measurement, 2012, 62(1): 50–59.
- 18 Jang JSR. ANFIS: adaptive-network-based fuzzy inference system. IEEE Transactions on Systems, Man, and Cybernetics, 1993, 23(3): 665–685. [doi: [10.1109/21.256541](https://doi.org/10.1109/21.256541)]

www.c-s-a.org.cn

www.c-s-a.org.cn