

基于季节模型及 Kalman 滤波的道路行程时间

孙 健¹, 张 纯^{1,2}, 陈书恺², 薛 睿², 彭仲仁^{1,3}

(1. 上海交通大学 船舶海洋与建筑工程学院, 海洋工程国家重点实验室, 上海 200240; 2. 上海交通大学 船舶海洋与建筑工程学院, 交通研究中心, 上海 200240; 3. 佛罗里达大学 城市与区域规划系, 佛罗里达州 盖恩斯维尔 32601)

摘 要:道路行程时间是影响城市交通出行行为的重要因素。当前大多数出行时间研究基于路段进行, 假设驾驶人沿着理想最短路径或最快路径行驶, 难以对交叉口排队延误等相关时间参数进行精确估计。针对城市任意 OD 间的出行时间进行分析, 采用 Kalman 滤波方法, 利用历史数据对总行程时间进行有效预测。鉴于总行程时间分布存在比较明显的周期性特点, 单一 Kalman 滤波算法难以反映出这种周期性, 引入基于季节模型的 Kalman 滤波算法进行建模和优化。最后, 利用深圳浮动车 2011 年 12 月连续 3 d 的数据进行实证。研究结果表明: 相对于传统的 SARIMA 模型及普通 Kalman 滤波算法, 优化模型同时考虑总行程时间分布的周期性和时变性, 具有较小误差及更好的拟合度; 所得预测时间的平均绝对误差(MAE)分别在传统 SARIMA 模型及普通 Kalman 滤波算法结果基础上降低了 37% 和 52%, 其余误差指标, 如均方根误差(RMSE)及最大相对误差(MRE)均有较大下降, 从而证明了研究模型的有效性。

关键词:交通工程; 城市交通; 总行程时间预测; 季节时间序列; Kalman 滤波算法; 浮动车数据

中图分类号:U491.1

文献标志码:A

Route travel time estimation based on seasonal model and Kalman filtering algorithm

SUN Jian¹, ZHANG Chun^{1,2}, CHEN Shu-kai², XUE Rui², PENG Zhong-ren^{1,3}

(1. State Key Laboratory of Ocean Engineering, School of Naval Architecture, Ocean and Civil Engineering, Shanghai Jiaotong University, Shanghai 200240, China; 2. Transportation Research Center, School of Naval Architecture, Ocean and Civil Engineering, Shanghai Jiaotong University, Shanghai 200240, China; 3. Department of Urban and Regional Planning, University of Florida, Gainesville 32611, Florida, USA)

Abstract: Travel time is a key factor affecting driving behavior in urban area. The majority of existing research focused on the link or section based travel time estimation and assumed that drivers generally choose the ideal shortest or fastest path. Hence, it's difficult to acquire accurate time estimation such as delays occurred in signalized intersections. This paper analyzes the travel time between OD pairs and estimates the total travel time based on historical data by using the Kalman filtering algorithm. Considering an ordinary Kalman filtering algorithm is not enough to capture the characteristic of periodicity, a seasonal Kalman filtering algorithm is proposed for the further modeling and optimization. Finally, the floating car data from three continuous days in December, 2011 (Shenzhen, China) were obtained for an empirical study. The re-

sults indicate that in comparison to the traditional SARIMA time series model and the ordinary Kalman filtering algorithm, the proposed model captures the periodicity and time variations of total travel time, and thus has higher accuracy and fitness. Compared to the results from SARIMA and the ordinary Kalman algorithms, the mean absolute errors (MAE) of the total travel time from the ordinary Kalman filtering predictions decrease 37% and 52%, respectively. The other two error related indexes, namely, the root mean square error (RMSE) and the maximum relative error (MRE) both decrease significantly, which consequently indicates the effectiveness of the proposed method, and further verifies the modelling capability of the seasonal Kalman filtering algorithm. 4 tabs, 5 figs, 15 refs.

Key words: traffic engineering; urban traffic; total travel time estimation; seasonal ARIMA model; Kalman filtering algorithm; floating car data

0 引言

城市道路行程时间是居民出行时十分关注的要素。传统基于路段的行程时间估算方法需考虑 2 个因素:驾驶人可能选择的道路以及驾驶人在所选路上可能遇到的交通状况。如 Miwa 等以成本最小路径做为驾驶人最可能行驶路径来预测 OD 间总行程时间^[1];Bhaskar 等则在预测时考虑信号交叉口对行程时间的影响^[2]。然而,由于单个驾驶人的驾驶习惯以及对路况判断不同,很难预测驾驶人实际会选择哪条道路。另外,由于城市路网密集,交通状况复杂多变,也很难对行驶路程中,特别是交叉口处可能遇到的交通状况全部考虑。因此,本文尝试忽略驾驶人路径选择及行程过程中的道路状况,通过直接对 OD 间总行程时间建模、分析其分布规律及发展特点。随着数据采集技术不断提高,直接分析任意 OD 间行程时间数据成为可能。目前,多种数据采集技术被利用于时间预测应用,张和生等采用固定检测器、浮动车、手机数据、RST 等设备对行程时间进行较准确的预测^[3-12]。对比各种数据采集技术可以看出,浮动车数据具有覆盖率大、实时性强、获取方便、成本较为低廉的优点,能较简单地对任意 OD 对进行分析。因此,本文采用浮动车数据对总行程时间进行预测。通过在出租车上安装 GPS 设备,每隔 1 s 接收一条记载有当前时间、该车辆瞬时速度、载客状况以及经纬度坐标等信息。借助这些数据,对所有出租车的行车轨迹进行追踪。利用数据匹配方法,得到任意 OD 对的历史总行程时间数据^[13]。同时,随着计算机及交通信息控制技术的快速发展,众多关于城市行程时间预测的模型不断被提出。Palacharla 等利用模糊算法、神经网络、Kalman 滤波等算法得到较准确的行程时间预测值^[3-5]。其中,Kalman 滤波算法由于具有较少的数据需求

量及较好自适应性而被广泛使用。然而,由于 OD 间总行程时间具有较明显的周期性,仅运用 Kalman 滤波算法很难对其周期性进行描述。因此,借鉴文献[6]涉及的加入季节模型的 Kalman 滤波算法,本文分别比较了基于路段及最短路径(最快路径)、基于 Kalman 滤波以及基于季节 Kalman 滤波的总行程时间算法,并得出结论;相对于传统 Kalman 滤波算法及时间序列算法,加入季节模型的 Kalman 滤波算法具有更好的拟合度。

1 数据处理

1.1 载客车次编号

本文利用浮动车数据建立基于 OD 的总行程时间预测模型。为了得到模型所需的 OD 间总行程时间,首先需找出所有来往于 OD 或经过 OD 的载客车次。由于出租车空载时存在寻客行为^[14],本文仅对载客运营的车辆进行编号。具体方法如下:

首先,根据出租车及时间对一天的浮动车数据进行排序;

其次,按顺序筛选载客车次(由多个连续载客状态为 1 的浮动车点组成),每筛选出一条载客车次,编号加 1。所有空载车次均标示为“NA”。

当一天中所有浮动车辆的所有载客车次均被编号后,停止编号。编号结果见下页表 1。

1.2 行程时间获取

确定合适扩展半径:考虑到车载 GPS 误差及实际情况,很难找到 2 个具有完全相同出发点及目的点的车次。因此,需要对 OD 点确定一个合适的扩展半径,在该扩展半径内,可认为是相同 O 点或 D 点。即只要某个车次中,有一个浮动车点落入出发地或目的地的扩展半径范围,就认为该车次经过该出发地或目的地。如果单个车次有 2 个浮动车点分别落入出发地和目的地的扩展半径范围内,则认为

表 1 载客车次编号

Tab. 1 Numbering items of taxi occupied by passengers

车号	时间	经度/(°)	纬度/(°)	载客状态 (0-空车; 1-载客)	编号
13500054264	00:08:30	114.0277	22.56317	1	1
13500054264	00:09:24	114.0245	22.56138	1	1
13500054264	00:19:22	113.9245	22.53090	1	1
13500054264	00:20:16	113.9228	22.52745	0	NA
13500054264	00:38:22	113.8951	22.56672	0	NA
13500054264	00:40:10	113.8960	22.56923	1	2
13500054264	00:41:04	113.8936	22.56563	1	2
13500054264	23:13:11	113.9044	22.55627	0	NA
13500054264	23:14:05	113.9047	22.55413	1	25
13500054264	23:59:57	113.9620	22.53475	1	25
13500054269	00:00:24	114.1167	22.54765	1	26
13500054269	00:01:18	114.1165	22.54662	1	26

该车次往返于或经过 OD。由于出行距离越大,具有相似出行特征的 OD 对分布范围越广,故本文选取 OD 间直线距离的给定百分比作为 OD 的扩展半径。该百分比既不能过小,否则会使许多具有相同性质的车次被遗漏;也不能过大,否则预测误差会较大。本文以高峰时段选取半径内所有车次平均速度的离散系数来选取合适的扩展半径。在高峰时段中,分别由小到大,测试不同百分比下所有车次评价速度的离散系数(标准差/均值)。若系数出现较大变化,则最大一个未出现较大变化的百分比即为所需的扩展百分比。

OD 行程时间获取:确定合适扩展半径后,以 OD 点为圆心,以所得扩展半径为半径作圆,得到出发点以及目的点的扩展范围。以该范围筛选出所有在该扩展范围内的浮动车点。对从 O 点和 D 点的扩展范围内筛选出的浮动车点进行编号匹配,筛选出所有往返于或经过 OD 的车次。根据出发点与目的点扩展范围内匹配点的时间差,即可得到该车次在 OD 间的行程时间。如有多个匹配的浮动车点,则选取与 OD 直线距离最近的两点,分别作为该车次 OD,再根据该两点的时间差,得到出租车在给定 OD 间的行程时间。获取 OD 总行程时间的步骤如图 1 所示。

2 行程时间预测

2.1 初始值获取

本文利用的浮动车数据主要来自深圳出租车的车载 GPS 设备,每天总共 3 000 多辆车,近 300 万

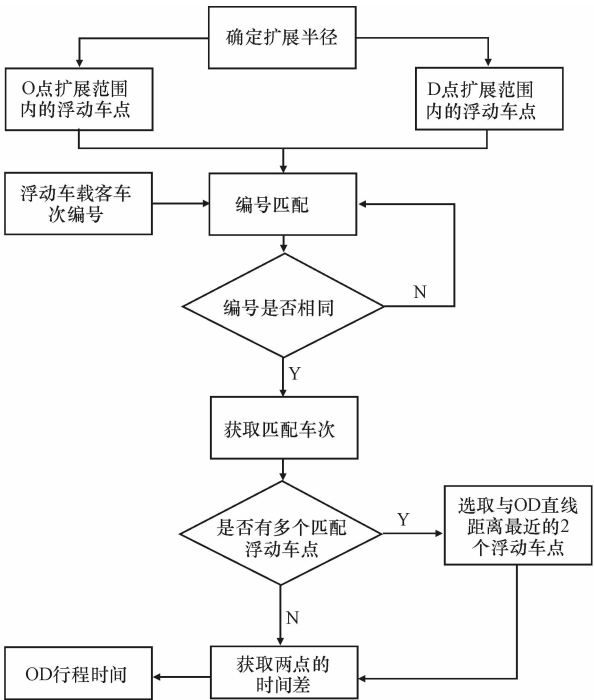



图 1 获取 OD 行程时间流程
Fig. 1 Flow of obtaining travel time

条行车数据。选取罗湖区与福田区,即深圳的商业中心(CBD)做为研究区域。这 2 个区域路网密度高,支路众多,居民交通出行频繁。由于存在众多支路和交叉口,驾驶人行车路线复杂,交通状况复杂多变,传统预测方法很难做出精确假设。对这些区域来说,基于路段的总行程时间预测存在较大误差,需考虑建立基于 OD 的总行程时间预测模型。

对所有载客车次进行编号,选择研究区域内任意两点为 OD 进行研究。选择合适的 OD 点扩展半径。利用 GIS 等工具,以 O(D)点为圆心,以选择的扩展半径为半径做圆,筛选出落在该圆范围内所有浮动车数据,如下页图 2 所示。图 2(a)为区域内所有浮动车点的投影图,2 个中心点即为所选的 OD 对,外部圆圈为根据选择的扩展半径作圆;图 2(b)为筛选出扩展圆范围内浮动车点的投影图。

对 OD 点扩展范围的选择,本文分别选择以 OD 直线距离的 6%、5%、4%、3%、2% 作为扩展百分比,以 5 min 为一个时段,在全天 288 个时段中,任选若干个时段,分别求每个时段所有车次总行程时间的离散系数(标准差/均值)。这些时段行程时间的离散系数如下页表 2 所示。

由表 2 可看出,扩展半径太小,则获得车次太少,离散系数较大,不能反映该半径内车次的共性;扩展半径太大,则很多没有共性的车次也被选中,离



(a) 所有浮动车数据图及OD扩展



(b) OD扩展范围内浮动车数据

图 2 获取 OD 扩展范围内的浮动车数据

Fig. 2 Obtained floating car data within OD range

散系数也较大。因而可以看出,扩展百分比设定为 3%较为合理。在该扩展半径内,各 OD 行程时间波动最小;在该范围下,OD 对特征最为相似。因此,以 OD 直线距离的 3%作为 OD 点扩展半径,筛选出该扩展范围内所有浮动车数据,并利用上述编号匹配方法,获得所有行驶于 OD 或通过 OD 的总行程时间数据。

表 2 不同扩展百分比的结果

Tab. 2 Testing results base on different percentages

百分比/%	离散系数
6	0.378
5	0.253
4	0.261
3	0.217
2	0.234

2.2 Kalman 滤波分析

Kalman 滤波算法根据上一时刻状态的最优估计值以及当前状态观测值,计算出当前状态的最优估计值。应用 Kalman 滤波,首先要确定其状态方程及测量方程。状态方程为

$$x(t)=A(t)x(t-1)+w_t \tag{1}$$

式中: $x(t)$ 为时刻 t 的预测行程时间; $A(t)$ 为时刻 t 的状态转移矩阵,即 $t-1$ 与 t 时刻总行程时间的相关系数,利用前一天同时段相关系数乘以一个修正系数作为当前时段的状态转移矩阵,该系数通过预

测当天已知时段的相关系数与前一天同时段的相关系数比值均值来确定,初始值为 1; w_t 为过程噪声,假定其符合均值为 0、方差为 Q_t 的正态分布, $w_t \sim N(0, Q_t)$ 。

测量方程表达式为

$$z(t) = B(t)x(t)+v_t \tag{2}$$

式中: $B(t)$ 为观测模型,可将真实状态空间映射成观测空间; v_t 为观测噪声,满足均值为 0、协方差矩阵为 R_t 的正态分布, $v_t \sim N(0, R_t)$ 。

本文以上一时段已到达目的地的所有浮动车的平均行程时间作为观测值,预测从当前或未来时段出发的行程的总时间。结合预测值和测量值,可得到当前状态 t 的最优估算值 $x_1(t)$

$$x_1(t)=x_0(t)+K(t)(z(t)-x_0(t)) \tag{3}$$

式中: $z(t)$ 为当前状态 t 的观测值; $x_0(t)$ 为上一状态的最优估算值; $K(t)$ 为 Kalman 增益。

$$K(t)=P_0(t)/(P_0(t)+R_t) \tag{4}$$

$$P_0(t)=P_1(t-1)+Q_t \tag{5}$$

式中: Q_t 为过程噪声 a_t 的协方差矩阵; R_t 为观测噪声 $v(t)$ 的协方差矩阵; $P_0(t)$ 为 $x_0(t)$ 的协方差。

得到 t 状态下的最优估计值 $x_1(t)$ 后,为了令 Kalman 滤波器不断迭代,直到系统过程结束,需对 t 状态下 $x_2(t)$ 的 covariance $P_1(t)$ 进行更新

$$P_1(t)=(1-K(t))P_0(t) \tag{6}$$

最后,更新 $t = t+1$,直到达到期望预测时段。

2.3 季节 Kalman 滤波算法

下页图 3 是根据深圳浮动车数据获取的某 OD 在 2011-12-4~2011-12-6 连续 3 d 内各时段的平均行程时间。图中横轴以 5 min 为一个时段,3 d 总共有 $3 \times 288 = 864$ 个时段。由于不同驾驶人在同一时段,同一 OD 的行驶时间各不相同,故本文取同一时段内所有行程时间的均值做为该时段的平均总行程时间。

由图 3 可看出,在每天早晚高峰时段,特别是晚高峰时段,总行程时间呈现出比较明显的峰值。且 3 d 总行程时间分布趋势大致相同,即每天各时段总行程时间分布呈现一定周期性。为了提高预测的精度,需要在 Kalman 滤波模型中引入季节因素。潘迪夫等在风电场风速预测中,曾利用时间序列分析直接推导出 Kalman 滤波的状态和测量方程,避免了推导 Kalman 状态和测量方程的困难^[15]。因而,本文首先以历史总行程时间数据对预测时段总行程时间做季节性时间序列分析,采用最优拟合方程作为季节 Kalman 滤波模型的状态模型。为了得




图 3 连续 3 d 内各时段平均行程时间分布

Fig. 3 Distribution of average travel time of each time period within three continuous days

到较高精度,本文以 5 min 为时段,将 1 d 分为 288 个时段。以每个车次的出发时间为判断依据,把所有车次划分到各个时段。对于相同时段中存在多个车次的状况,取这些车次的平均值作为该时段 OD 行程时间。由于 5 min 时段较短,可能存在某个时段没有总行程时间数据的情况,故本文以该时段前一时段和后一时段的平均值作为其总行程时间数据。

取周期 288,对总行程时间 x_t 的对数 $\ln(x_t)$ 做一阶差分和一阶季节性差分,得 $\Delta\Delta_{288}\ln(x_t)$ 。从 $\Delta\Delta_{288}\ln(x_t)$ 的相关图和偏相关图,可看出其近似为平稳过程,如图 4 所示,其中 y 为 $\Delta\Delta_{288}\ln(x_t)$ 行程时间的对数的一次差分及一次季节差分结果。

基于上述分析,考虑选用 SARIMA(0,1,1), $X(0,1,1)_{288}$ 模型,选取 288 为周期,其表达式为

$$(1-B^{288})(1-B)\ln(x_t) = (1-\theta_1 B)(1-\theta_{288} B^{288})a_t \quad (7)$$

式中: B 为滞后算子,即 $Bx_t = x_{t-1}$; $1-B^{288}$ 、 $1-B$ 分别为季节性差分和非季节性差分; θ_{288} 、 θ_1 分别为季节性和非季节性滑动平均因子。

模型主要由两部分组成,前一部分为季节性自回归方程

$$(1-B^{288})\ln(x_t) = (1-\theta_{288} B^{288})e_t \quad (8)$$

主要考虑不同天相同时段数据间的相互关系。

另一部分为非季节性自回归方程


$$(1-B)e_t = (1-\theta_1 B)a_t \quad (9)$$

该部分主要刻画同一天不同时段数据间的相互关系。


式中: a_t 为白噪声序列,满足均值为 0、协方差矩阵为 Q_t 的正态分布, $a_t \sim N(0, Q_t)$; e_t 为系数。

运用 Eviews 软件,代入历史数据,得到拟合模型为

$$(1-B^{288})(1-B)\ln(x_t) = (1+0.895\ 991B) \cdot (1+0.235\ 26B^{288})a_t \quad (10)$$



(a) $\ln(x_t)$ 分布



(b) $\ln(x_t)$ 自相关、偏相关

图 4 一阶差分和一阶季节性差分后的 $\ln(x_t)$

Fig. 4 $\ln(x_t)$ of the first difference and second order difference

对式(4)展开,则有

$$\begin{aligned} \ln(x_t) = & \ln(x_{t-1}) + \ln(x_{t-288}) - \ln(x_{t-289}) + \\ & a_t + 0.895\ 991a_{t-1} + 1.023\ 526a_{t-288} + \\ & 0.917\ 1a_{t-289} \end{aligned} \quad (11)$$

其输出结果如下页表 3 所示。

由表 3 可看出,MA(1)和 SMA(288)的 P 值非常小,即模型解释变量的系数估计值非常显著。同时,利用 Q 统计量对模型进行诊断,得到 P 值均非常小,说明模型较好地拟合数据。然而,时间序列模型的动态预测结果拟合度较低,很难适应实时交通状况。

如建立更高阶的季节时间序列模型,则不但需要过多的历史数据,而且依然很难反映路网交通流

的时变性。因而,本文考虑将该拟合方程作为 Kalman 滤波模型的状态方程,得到比较精确的动态预测模型。

表 3 不同扩展百分比的结果

Tab. 3 Testing results base on different percentages				
变量	系数	标准误差	<i>t</i> 统计量	<i>P</i> 值
MA(1)	−0.896	0.019	−48.099	0
SMA(288)	−1.024	0.054	−18.980	0
<i>R</i> ²	0.679	因变量均值		−0.001
Adjusted <i>R</i> ²	0.679	因变量标准差		0.191
D-W 统计量	2.001			

因此,季节 Kalman 滤波模型的状态方差为

$$x_0'(t)=\ln(x_1(t-1))+\ln(x_1(t-288))-$$
$$\ln(x_1(t-289))+a_t+0.895\ 991a_{t-1}+$$
$$1.023\ 526a_{t-288}+0.917\ 1a_{t-289}\tag{12}$$

$$x_0(t)=e^{x_0'(t)}\tag{13}$$

式中: $x_0'(t)$ 为 t 时段预测状态值的自然对数; $x_0(t)$ 为 t 时段预测状态值; $x_1(t-k)$ 为 k 时段前最优估计, k 取 1、288、289。

本文以该时段实际测量值设定为模型初始值,即认为作为模型初始值计算开始的第 1 个周期最优估计值与该时段实际观测值相等,其他初始值也以第 1 个周期实际值设定。

$$a_{t-k}\sim N(0,\boldsymbol{Q}_{t-k}),\ k=1,288,289$$

同样,运用上述基于季节时间序列模型,利用历史观测数据获得当前的观测值,即

$$z'(t)=\ln(x(t-1))+\ln(x(t-288))+$$
$$\ln(x(t-289))+v_t+0.895\ 991v_{t-1}+$$
$$1.023\ 526v_{t-288}+0.917\ 1v_{t-289}\tag{14}$$

$$z(t)=e^{z'(t)}\tag{15}$$

式中: $x(t-k)$ 为历史观测值, k 取 1、288、289。

2.4 预测及结果分析

以深圳市 2011-12-4 的浮动车数据作为历史数据,对 2011-12-5 晚高峰时段(17:30~19:30)行程时间进行预测。图 5 给出分别利用 SARIMA 模型、普通 Kalman 滤波模型及季节 Kalman 滤波模型进行行程时间预测的结果(横轴为 24 个时段,每个时段为 5 min,共 2 h)。

可以看出,普通 Kalman 滤波算法有明显滞后性,而结合季节模型后的 Kalman 滤波算法则拟合度较高。同时,相对基于季节模型的时间序列算法,其拟合度进一步得到提高。特别是当存在较大波动时,单一季节时间序列模型解释度较差,而加入季节模型 Kalman 滤波算法后,拟合程度显著提高。3 种

模型的平均绝对误差(MAE)、均方根误差(RMSE)、最大相对误差(MRE)如表 4 所示。




图 5 SARIMA 模型、普通 Kalman 滤波及季节 Kalman 滤波预测结果比较

Fig. 5 Comparison of predicting results using SARIMA, ordinary Kalman filtering and season Kalman filter models

表 4 各种预测方法的误差比较

预测方法	MAE		RMSE		MRE	
	绝对值	百分比/%	绝对值	百分比/%	绝对值	百分比/%
普通 Kalman	176.8	10.07	189.2	11.95	453.7	26.31
季节 Kalman	85.4	4.88	93.6	6.38	348.9	20.34
SARIMA	136.6	8.43	141.2	8.56	198.5	10.91

由上述误差分析可知,普通 Kalman 滤波算法的预测误差较大,而季节 Kalman 滤波算法的精度明显提高。相比 SARIMA 时间序列算法,虽然季节 Kalman 滤波预测波动略有增加,但预测精度有了较大提高。

3 结 语

(1) 城市道路行程时间是影响居民出行及交通流诱导策略的重要因素。本文首先利用深圳市 2011 年 12 月连续 3 d 的浮动车数据,获取 OD 间总行程时间。其次对行程时间分布规律及变化特征进行分析。最后针对 OD 间行程时间变化的周期性和时变性建立基于季节模型及 Kalman 滤波算法的优化模型,对城市道路行程时间进行预测。

(2) 相比传统基于路段的总行程时间预测方法,本文基于城市区域 OD 对总行程时间分布规律及变化特征进行分析,避免对驾驶人路径选择行为进行假设,也不需要考虑交叉口排队等行程中可能遇到的延误,提高了数据可靠性。

(3) 基于深圳市浮动车数据的案例表明,相对传统的 SARIMA 时间序列模型及普通 Kalman 滤波算法,优化模型(加入季节模型的 Kalman 滤波算法)同

时考虑总行程时间分布的周期性和时变性,具有较小误差及更好的拟合度,消除了普通Kalman滤波算法的预测滞后性;所得预测时间的平均绝对误差(MAE)分别在传统SARIMA模型及普通Kalman滤波算法结果基础上提高了37%和52%,其余误差指标,如均方根误差(RMSE)、最大相对误差(MRE)均有较大提高,从而证明了研究模型的有效性。

(4) 本文没有对影响季节模型及Kalman滤波算法预测精度的相关因素进行详细分析。同时,行程时间预测模型在城市交通事件发生或特殊状况下的应用还需进一步验证。

参考文献:

References:

- [1] Miwa T, Sakai T, Morikawa T. Route identification and travel time prediction using probe-car data[J]. International Journal of ITS Research, 2004, 2(1): 21-28.
- [2] Bhaskar A, Chung E, Dumont A G. Estimation of travel time on urban networks with midlink sources and sinks[J]. Transportation Research Record: Journal of the Transportation Research Board, 2009 (2121): 41-54.
- [3] 张和生, 张毅, 温慧敏, 等. 利用GPS数据估计路段的平均行程时间[J]. 吉林大学学报: 工学版, 2007, 37(3): 533-537.
ZHANG He-sheng, ZHANG Yi, WEN Hui-min, et al. Estimation approaches of average link travel time using GPS data[J]. Journal of Jilin University: Engineering and Technology Edition, 2007, 37(3): 533-537. (in Chinese)
- [4] Nanthawichit C, Nakatsuji T, Suzuki H. Application of probe vehicle data for real-time traffic state estimation and short term travel time prediction on a freeway[J]. Transportation Research Record: Journal of the Transportation Research Board, 2007 (1855): 49-59.
- [5] Ygnace J L, Drane C, Yim Y B, et al. Travel time estimation on the san francisco bay area network using cellular phones as probes[R]. Berkeley: University of California-Berkeley, 2000.
- [6] Kwon J, Coifman B, Bickel P. Day-to-day travel time trends and travel time prediction from loop detector data [J]. Transportation Research Record: Journal of the Transportation Research Board, 2000(1554): 120-129.
- [7] Wang J Q, Niu H M. Graded-information feedback strategy in two-route systems under ATIS[J]. Journal of Traffic and Transportation Engineering: English Edition, 2014, 1(2): 138-145.
- [8] Kuchipudi C M, Chien S I J. Development of a hybrid model for dynamic travel time prediction[J]. Transportation Research Record: Journal of the Transportation Research Board, 2008(1855): 22-31.
- [9] Palacharla P V, Nelson P C. Application of fuzzy logic and neural networks for dynamic travel time estimation[J]. International Transactions in Operational Research, 1999, 6(1): 145-160.
- [10] Semeida A M. Derivation of travel demand forecasting models for low population areas; the case of Port Said Governorate, North East Egypt[J]. Journal of Traffic and Transportation Engineering: English Edition, 2014, 1(3): 196-208..
- [11] Chen M, Chien S I J. Dynamic freeway travel time prediction using probe vehicle data: link-based vs. psth-based [J]. Transportation Research Record: Journal of the Transportation Research Board, 2007 (1768): 157-161.
- [12] 曹欣荣, 楼骏. 基于卡尔曼滤波模型的时用水量预测[J]. 浙江水利科技, 2008(2): 26-28.
CAO Xin-rong, LOU Jun. Analysis of prediction for hourly water consumption based on improved kalman model[J]. Zhejiang Hydrotechnics, 2008(2): 26-28. (in Chinese)
- [13] Sun J, Zhang L. Vehicle actuation based short term traffic flow prediction model for signalized intersections[J]. Journal of Central South University: English Version, 2012, 19(1): 287-298.
- [14] 孙健, 刘琼, 彭仲仁. 城市交通拥挤成因及时空演化规律分析-以深圳市为例[J]. 交通运输系统工程与信息, 2011, 11(5): 86-93.
SUN Jian, LIU Qiong, PENG Zhong-ren. Research and analysis on causality and spatial-temporal evolution of urban traffic congestions-a case study on Shenzhen of China[J]. Transportation Systems Engineering and Information, 2011, 11(5): 86-93. (in Chinese)
- [15] 潘迪夫, 刘辉, 李燕飞. 基于时间序列分析和卡尔曼滤波算法的风电场风速预测优化模型[J]. 电网技术, 2008, 32(7): 82-86.
PAN Di-fun, LIU Hui, LI Yan-fei. A wind speed forecasting optimization model for wind farms based on time series analysis and Kalman filter algorithm [J]. Power System Technology, 2008, 32(7): 82-86. (in Chinese)