

doi: 10.3969/j.issn.1002-0268.2015.05.023

基于混合粒子滤波的高速公路交通参数 自适应估计方法

尹春娥, 宋小娜, 刘海朝
(华北水利水电大学, 河南 郑州 450011)

摘要:为提高高速公路交通参数的估计准确度,在宏观交通流模型和状态空间模型的基础上,基于贝叶斯理论,提出了一种基于混合粒子滤波的交通参数估计方法。考虑到估计结果对模型参数变化的敏感性,避免采用预设固定模型参数对估计准确度的影响,通过建立自由流速度与饱和度之间的变化关系,提出了交通状态影响下的模型参数自适应调整策略。仿真结果表明:基于混合粒子滤波的交通参数估计准确度要明显高于卡尔曼滤波估计,在正常和事故场景下,能够快速识别交通量和速度较明显的波动,表现出了更强的稳定性;交通状态影响下的模型参数自适应调整策略会明显提高交通参数估计准确度,在发生事故情况下,也可达到较好的估计效果。

关键词: 交通工程; 高速公路; 交通流; 交通参数估计; 混合粒子滤波; 自适应调整

中图分类号: U491.1

文献标识码: A

文章编号: 1002-0268(2015)05-0141-06

A Method of Expressway Traffic Parameter Self-adaptive Estimation Based on Hybrid Particle Filtering

YIN Chun-e, SONG Xiao-na, LIU Hai-chao

(North China University of Water Resources and Electric Power, Zhengzhou Henan 450011, China)

Abstract: In order to improve the accuracy of expressway traffic parameter estimation, a traffic parameter estimation method based on HPF is proposed based on macroscopic traffic flow model and state-space model according to Bayesian theory. Considering the sensitivity of the estimation result to the model parameters and avoiding the effect of using preset fixed model parameters on the estimation accuracy, a self-adaptive adjustment strategy for model parameters under the influence of traffic state is proposed through establishing the relationship between free-flow speed and saturation. The simulation result shows that (1) the traffic parameter estimation accuracy based on HPF is obviously higher than that of Kalman filtering, it is able to quickly identify the obvious fluctuations of traffic volume and speed under normal and accident traffic conditions, which reflects a higher stability; (2) the self-adaptive adjustment strategy of model parameter under the influence of traffic conditions can obviously improve the estimation accuracy and achieve better estimation effect even in case of accident.

Key words: traffic engineering; expressway; traffic flow; traffic parameter estimation; hybrid particle filtering (HPF); self-adaptive adjustment

0 引言

高速公路交通参数估计是高速公路交通管理与

控制的基础工作^[1-2],主要是基于实时的交通监测来估计路网中当前时刻及下一时刻的所有交通参数^[3]。早期研究多用基于卡尔曼滤波的方程来进行

收稿日期: 2014-07-11

基金项目: 国家自然科学基金项目(51208051); 河南省2014交通厅科技攻关项目(2014G27); 河南省高等学校重点科研项目(15A580004)

作者简介: 尹春娥(1976-),女,山东莱州人,博士,副教授。(yce@ncwu.edu.cn)

估计,如扩展卡尔曼滤波(Extended Kalman Filtering, EKF)^[4-6]和无迹卡尔曼滤波(Unscented Kalman Filtering, UKF)^[7-9]。基于卡尔曼滤波参数估计的运算量较小,具有一定的准确性和有效性。但由于交通参数估计实质是一个非线性和非高斯问题,EKF和UKF仍然不能避免随着交通场景的变化呈现出很多不确定性和多样性的误差。而粒子滤波器作为一种可对非线性和非高斯系统直接进行估计的方法,可以有效避免EKF方法的模型线性化问题,近年来逐渐被应用于交通参数估计中^[10-11]。

交通状态估计模型中的参数通常会随交通状态的变化而变化。例如,当估计对象选定为宏观交通流模型时,估计结果对自由流速度、临界密度及相关指数的变化是非常敏感的^[12]。在已有研究中,并未考虑到交通状态对估计结果参数的影响,解决方法是将模型中的参数通过离线模型校正采用预设固定参数,致使交通参数估计的准确度受到一定程度的影响^[4-9]。

为达到更高的估计准确度,本文提出一种基于混合粒子滤波(Hybrid Particle Filtering, HPF)的交通参数估计方法,以及交通状态影响下的模型参数自适应调整策略,并通过仿真数据对该方法与策略进行论证分析。

1 参数估计方法研究

1.1 高速公路路段的宏观交通流模型

将高速公路通道分成很多路段,每段长度是 Δ_i , $i=1, \dots, N$,时间的离散化是基于时间步 T 。交通变量有:交通密度 $\rho_i(k)$ 、空间平均速度 $v_i(k)$ 、交通流量 $q_i(k)$ 、路段 i 上的入口匝道流量 $r_i(k)$ 和出口匝道流量。

对于路段 i ,二阶宏观交通流模型的随机非线性差分方程为:

$$\begin{aligned} \rho_i(k+1) &= \rho_i(k) + \frac{T}{\Delta_i \lambda_i} [q_{i-1}(k) - q_i(k) + r_i(k) - s_i(k)], \quad (1) \\ s_i(k) &= \beta_i(k) q_{i-1}(k), \quad (2) \\ v_i(k+1) &= v_i(k) + \frac{T}{\tau} \{V[\rho_i(k)] - v_i(k)\} + \frac{T}{\Delta_i} v_i(k) [v_{i-1}(k) - v_i(k)] - \frac{vT}{\tau \Delta_i} \cdot \\ &\quad \frac{[\rho_{i+1}(k) - \rho_i(k)]}{\rho_i(k) + \kappa} - \frac{\delta T}{\Delta_i \lambda_i} \cdot \frac{r_i(k) v_i(k)}{\rho_i(k) + \kappa} + \xi_i^v(k), \quad (3) \end{aligned}$$

$$V(\rho) = v_f \exp \left[-\frac{1}{\alpha} \left(\frac{\rho}{\rho_{cr}} \right)^\alpha \right], \quad (4)$$

$$q_i(k) = \rho_i(k) v_i(k) \lambda_i + \xi_i^q(k). \quad (5)$$

式(1),式(3),式(4),式(5)分别为经典的密度动态模型、速度动态模型、静态速度方程和交通流方程; τ , v , κ , v_f , ρ , ρ_{cr} , α , δ 为模型参数,所有路段都采用相同的参数值; τ 为车速变化比前方 Δx 处密度变化的滞后时间,也是对驾驶员反应时间的度量; v 为速度影响传播速度; κ 为常数,当 ρ_i 很小时,该项不至于出现很大、与实际不符的数值; v_f 为自由流速度; ρ_{cr} 为临界密度; α 为静态速度方程中的指数。 $\xi_i^v(k)$ 和 $\xi_i^q(k)$ 分别为作用在经验速度方程和近似交通流方程上的零均值高斯白噪声,用于反映模型误差; $\beta_i(k)$ 为车辆离开率; λ_i 为车道数量。

模型结果对 v_f , ρ_{cr} , α 的变化是非常敏感的^[3],本文选取这3个参数作为未知模型参数。基于交通量 $Q(\rho) = \rho V(\rho)$,路段的通行能力(每车道)可以推导为:

$$q_{cap}(v_f, \rho_{cr}, \alpha) = v_f \rho_{cr} \exp \left[-\frac{1}{\alpha} \right]. \quad (6)$$

将式(2)和式(5)代入式(1)和式(4),最后代入式(3),这样 N 个路段的通道模型就包含了 $2N$ 个方程和 $2N$ 个独立的段变量 $\rho_1, v_1, \rho_2, v_2, \dots, \rho_N, v_N$, 3个模型参数 v_f, ρ_{cr}, α 以及一系列边界变量:(1)通道起点的交通流 q_0 ;(2)通道起点的速度 v_0 ;(3)通道终点的密度 ρ_{N+1} ;(3)入口匝道交通流 r_i ;(4)出口匝道交通流率 β_i 。

1.2 状态空间模型

由 N 个路段组成的通道模型所包含的全部变量可以包含在向量 $\mathbf{z}$, $\mathbf{d}$, $\mathbf{p}$ 和 $\boldsymbol{\xi}_1$ 中,其中,路段状态向量 $\mathbf{z}$ 由通道中 N 个路段的密度和速度组成,代表了模型的状态,表示为:

$$\mathbf{z} = [\rho_1 v_1, \rho_2 v_2, \dots, \rho_N v_N]^T. \quad (7)$$

边界向量 $\mathbf{d}$ 由宏观交通流模型的通道边界处的参数组成,代表了模型的外部输入,表示为:

$$\mathbf{d} = [q_0 v_0, \rho_{N+1}, r_1, \dots, r_N, \beta_1, \dots, \beta_N]^T. \quad (8)$$

模型参数向量 $\mathbf{p}$ 包含了未知的重要模型参数,代表了模型的一些重要内在特性,表示为:

$$\mathbf{p} = [v_f, \rho_{cr}, \alpha]^T. \quad (9)$$

噪声向量 $\boldsymbol{\xi}_1$ 表示为:

$$\boldsymbol{\xi}_1 = [\xi_1^q, \xi_1^v, \dots, \xi_N^q, \xi_N^v]^T. \quad (10)$$

快速通道的宏观交通流模型可以表示为一个紧凑的状态空间形式:

$$\mathbf{z}(k+1) = h[\mathbf{z}(k), \mathbf{d}(k), \mathbf{p}(k), \boldsymbol{\xi}_1(k)]。 (11)$$

h 为非线性可微向量的函数。为克服模型参数造成的误差,将式(11)中的边界变量 $\mathbf{d}(k)$ 和模型参数 $\mathbf{p}(k)$ 转换成如下形式:

$$\mathbf{d}(k+1) = \mathbf{d}(k) + \boldsymbol{\xi}_2(k), \quad (12)$$

式中 $\boldsymbol{\xi}_2(k)$ 为零均值高斯白噪声向量。相似地,模型参数建模如下:

$$\mathbf{p}(k+1) = \mathbf{p}(k) + \boldsymbol{\xi}_3(k), \quad (13)$$

式中 $\boldsymbol{\xi}_3(k)$ 为零均值高斯白噪声向量,结合式(11)~式(13)得出扩展状态空间模型:

$$\mathbf{x}(k+1) = f[\mathbf{x}(k), \boldsymbol{\xi}(k)], \quad (14)$$

式中, $\mathbf{x} = [\mathbf{z}^T, \mathbf{d}^T, \mathbf{p}^T]^T$; $\boldsymbol{\xi} = [\boldsymbol{\xi}_1^T, \boldsymbol{\xi}_2^T, \boldsymbol{\xi}_3^T]^T$; 并且非线性可微向量的函数 f 也相应地被确定下来。在 $\mathbf{x}$ 的辅助下,式(6)~式(10)的测量可通过紧凑形式重写如下:

$$\mathbf{y}(k) = g[\mathbf{x}(k), \boldsymbol{\eta}(k)]。 \quad (15)$$

输出向量 $\mathbf{y}$ 包含所有可用于交通流和平均速度的测定; g 是一个非线性可微向量的函数; $\boldsymbol{\eta}$ 为输出噪声向量,它可以被视为状态噪声向量 $\boldsymbol{\xi}$ 和测定噪声向量 $\boldsymbol{\gamma}$ 的函数。式(14)和式(15)组成空间模型为:

$$\sum (x, y): \begin{cases} \mathbf{x}(k+1) = f[\mathbf{x}(k), \boldsymbol{\xi}(k)] \\ \mathbf{y}(k) = g[\mathbf{x}(k), \boldsymbol{\eta}(k)] \end{cases}。 \quad (16)$$

1.3 基于混合粒子滤波 HPF 的交通参数估计方法

本文所关注的状态空间模型为式(16)。根据贝叶斯理论,后验概率 $p(\mathbf{x}_{0:k+1} | \mathbf{y}_{0:k+1})$ 包含了对状态 $\mathbf{x}_{0:k+1}$ 估计的所有信息。粒子滤波算法通过在重要性分布 $\pi(\cdot)$ 采样获得一组离散样本点 $\{\mathbf{x}_{0:n}^i\}_{i=1}^N$ 来近似计算后验概率,并得到粒子的重要性权重:

$$\omega_{k+1}^i = \frac{p(\mathbf{x}_{0:k+1}^i | \mathbf{y}_{0:k+1})}{\pi(\mathbf{x}_{0:k+1}^i | \mathbf{y}_{0:k+1})} = \omega_k^i \frac{p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}^i) p(\mathbf{x}_{k+1} | \mathbf{x}_k^i)}{\pi(\mathbf{x}_{k+1}^i | \mathbf{y}_{k+1}, \mathbf{x}_{0:k}^i)}, \quad (17)$$

$i = 1, \dots, N。$

在先验概率分布 $p(\mathbf{x}_0)$ 上采样获得粒子,然后通过概率分布:

$$\pi(\mathbf{x}_{k+1}^i | \mathbf{y}_{k+1}, \mathbf{x}_{0:k}^i) = p(\mathbf{x}_{k+1}^i | \mathbf{x}_k^i)。 \quad (18)$$

更新粒子并假设状态噪声服从高斯分布,有:

$$p(\mathbf{x}_{k+1}^i | \mathbf{x}_k^i) = N(\mathbf{M}_1, \mathbf{Q}), \quad (19)$$

式中, $\mathbf{M}_1 = f[\mathbf{x}_k^i, \boldsymbol{\xi}(k)]$; $\mathbf{Q}$ 为状态噪声协方差矩阵。

粒子重要性权重为:

$$\omega_{k+1}^i = \omega_k^i p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}^i)。 \quad (20)$$

似然函数为:

$$p(\mathbf{y}_{k+1} | \mathbf{x}_{k+1}^i) = N(g\mathbf{M}_2, \sigma^2), \quad (21)$$

式中, $\mathbf{M}_2 = [\mathbf{x}_{k+1}^i, \boldsymbol{\eta}(k+1)]$; σ^2 为高斯分布方差,再经归一化后有:

$$\tilde{\omega}_{k+1}^i = \omega_{k+1}^i / \sum_{i=1}^N \omega_{k+1}^i。 \quad (22)$$

状态 $\mathbf{x}_{k+1}$ 的最小均方估计可表示为:

$$\hat{\mathbf{x}}_{k+1}^{MMSE} = \sum_{i=1}^N \mathbf{x}_{k+1}^i \tilde{\omega}_{k+1}^i。 \quad (23)$$

为防止较大观测噪声造成后验概率描述不准而影响性能,考虑对状态 $\mathbf{x}_{k+1}$ 的顺序估计满足:

$$\hat{\mathbf{x}}_{k+1} = f[\hat{\mathbf{x}}_k, \boldsymbol{\xi}(k)], \quad (24)$$

并估计 $\hat{\mathbf{x}}_{k+1}^{MMSE}$ 与 $\hat{\mathbf{x}}_{k+1}$ 之间满足:

$$\hat{\mathbf{x}}_{k+1}^{MMSE} = \hat{\mathbf{x}}_{k+1} + \mathbf{e}_{k+1}, \quad (25)$$

式中, $\mathbf{e}_{k+1}$ 为最小均方估计与最优估计间的误差,它服从均值为0;协方差矩阵为 $\boldsymbol{\varphi}$ 的高斯分布。

考虑卡尔曼滤波得到最优估计 $\hat{\mathbf{x}}_{k+1}$, 有:

$$\mathbf{P}_{k+1|k} = f(\cdot) \mathbf{P}_{k|k} f^T(\cdot) + \mathbf{Q}, \quad (26)$$

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1|k} (\boldsymbol{\varphi} + \mathbf{P}_{k+1|k})^{-1}, \quad (27)$$

$$\mathbf{P}_{k+1|k+1} = (\mathbf{I} - \mathbf{K}_{k+1}) \mathbf{P}_{k+1|k}, \quad (28)$$

$$\hat{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_k + \mathbf{K}_{k+1} (\hat{\mathbf{x}}_k^{MMSE} - \hat{\mathbf{x}}_k), \quad (29)$$

式中, $\mathbf{P}_{k+1|k}$ 为先验估计误差协方差矩阵; $\mathbf{K}_{k+1}$ 为卡尔曼增益矩阵; $\mathbf{I}$ 为单位矩阵; $\mathbf{P}_{k+1|k+1}$ 为后验估计误差协方差矩阵。HPF 估计由两项组成:(1)模型项在每个时间段 k 上进行的纯粹基于模型的状态估计;(2)校正项是基于从每个时间段 k 上收集来的实时测量。若粒子的初始分布服从均匀分布 $\Omega(\cdot)$, 则先验概率分布为:

$$p(\mathbf{x}_0) = \Omega(a, b), \quad (30)$$

式中 a, b 分别为均匀分布的下界和上界,则卡尔曼滤波的初始值为:

$$\hat{\mathbf{x}}_0 = \frac{a+b}{2}, \mathbf{P}_{0|0} = \frac{(b-a)(b-a)^T}{12} \mathbf{I}, \quad (31)$$

式中 $\mathbf{I}$ 为单位矩阵。

1.4 交通状态影响下的模型参数自适应调整

由宏观交通流模型可知,参数估计结果对自由流速度、临界密度和指数的变化是非常敏感的。由于临界密度与指数是相对固定且不随交通运行条件改变的,而自由流速度则容易受到道路条件如车道数、平曲线半径、进出口匝道距离及交通运行条件如饱和度(V/C)的影响。因此,考虑将自由流速度作为未知的模型参数,其他模型参数都由离线模型校正来决定。在仿真试验分析中,将会根据具体数据给出自由流速度与交通饱和度之间的函数关系,以期基于交通状态自适应变化的自由流实测速度取代预设固定的自由流速度,通过自由流速度的自适

应调整,达到更高的估计准确度。

1.5 性能评价指标

选用绝对和相对性能指标来评估参数轨迹性能^[12],绝对性能指标为:

$$RMSE_A = \sqrt{\frac{1}{KN} \sum_{k=0}^K \sum_{i=1}^N \{x_i(k) - \hat{x}_i[k/(k-1)]\}^2}, \quad (32)$$

相对性能指标为:

$$RMSE_R = \frac{RMSE_A}{\frac{1}{KN} \sum_{k=0}^K \sum_{i=1}^N x_i(k)}, \quad (33)$$

式中 K 为仿真时间跨度; N 为路段的数量; x_i 为路段密度或速度; $\hat{x}_i$ 为对应的评估。

2 仿真试验

为了检验所提出模型的估计效果,对高速公路交通参数估计进行仿真分析,对路段上的速度及交通量进行估计。仿真方案分为正常和发生事故两种情况。仿真在 Matlab 环境下进行,对于每种情况,分别采用 EKF, UKF, HPF 进行交通参数估计并比较性能;然后,再将自适应调整策略应用到 EKF, UKF 和 HPF 中,进行综合比较分析。

2.1 仿真环境介绍

仿真公路如图 1 所示。仿真实例选择 1 条 5.6 km 长的高速公路,将该路平均分成 7 个路段,编号为 1,2,...,7,在 5 号路段开设有进口匝道。假设该路段上有 3 个交通检测器,分别为 D1, D2, D3, 被分别安装在路段入口、出口以及第 5 号路段与第 6 号路段的交界处。仿真时间跨度设置为 8 h, 时间为 12:00—20:00。仿真入口的交通量曲线和速度曲线分别如图 2 和图 3 所示。状态向量定义如下:

$$\mathbf{x} = [\rho_1, v_1, \dots, \rho_7, v_7, r_5, v_f, \rho_{cr}, \alpha]。 \quad (34)$$




图 1 仿真路段道路结构与交通检测器配置

Fig. 1 Structure of simulation section and configuration of traffic detectors

参数设计如下: $\tau = 20$ s, $v = 35$ km²/h, $\delta = 1.4$, $\kappa = 13$ veh/(km · lane), $v_f = 120$ km/h, $\rho_{cr} = 40$ veh/km, $\alpha = 2$ 。状态每 10 s 更新 1 次,而观测数




图 2 仿真路段入口交通流量

Fig. 2 Traffic flows of simulation section entrance




图 3 仿真路段入口速度曲线

Fig. 3 Velocity curve of simulation section entrance

据每 60 s 到达 1 次。仿真过程中所有的噪声都假设为零均值的高斯白噪声。基于经验选定标准差,粒子数量 $N = 300$, 其他标准差取值如下:

$$D[\xi_1^q(k)] = 100 \text{ veh/h}, D[\xi_1^v(k)] = 10 \text{ km/h},$$

$$D[\xi_0^q(k)] = 100 \text{ veh/h}, D[\xi_0^v(k)] = 4.5 \text{ km/h}。$$

2.2 自由流速度随交通状态的自适应变化

通过记录仿真过程中实测自由流速度与饱和度的数据,计算得到仿真过程中速度与饱和度之间的关系如图 4 所示,建立回归模型如式 (35) 所示。最大绝对误差值为 5.91 km/h,最大相对误差为 6.25%,误差较小,可以用于试验分析。

自由流速度为:

$$V_f = -231.2 (V/C)^2 - 25.42 (V/C) + 123.4, \quad (35)$$

式中 V/C 为饱和度。




图 4 仿真条件下自由流速度观测值与交通饱和度曲线关系图

Fig. 4 Observed free flow speeds and curves of traffic saturation under simulation condition

2.3 正常情况下的高速公路交通参数估计

图 5 显示了正常情况下利用 EKF, UKF, HPF

进行交通参数(交通量和速度)估计的情况。对比发现, HPF 的估计曲线和实际情况拟合程度高于 EKF 和 UKF, 能够迅速地识别交通量和速度较明显的波动。当采用了参数自适应调整后, 交通量和速度估计曲线与实际情况的拟合程度明显好于无参数自适应调整的情况。从表 1 可以进一步看出, 参数自适应调整能较明显地提高估计准确度, 而且 HPF 的性能要明显高于 EKF 和 UKF。




图5 正常情况下基于仿真数据的交通参数估计

Fig. 5 Estimation of traffic parameters based on simulation data under normal condition

2.4 事故情况下的高速公路交通参数估计

假设在 13:00 整检测器 D2 处发生了交通事故, 占用了 1 条车道, 事故持续了 30 min, 在 13:30 结束。在图 6 中显示了发生事故情况下采用 EKF, UKF, HPF 进行交通参数估计的情况。可以发现, 采用 HPF 进行交通参数的估计曲线和实际曲线

表1 正常情况下基于仿真数据的 EKF、UKF 和 HPF 的性能比较
Tab. 1 Comparison of properties of EKF, UKF and HPF based on simulation data under normal condition

参数	交通量				速度			
	无调整		调整后		无调整		调整后	
性能指标	$RMSE_a$	$RMSE_t / RMSE_a$ %	$RMSE_a$	$RMSE_t / RMSE_a$ %	$RMSE_a$	$RMSE_t / RMSE_a$ %	$RMSE_a$	$RMSE_t / RMSE_a$ %
EKF	3.408	25.67	3.126	22.34	14.365	18.21	12.704	15.80
UKF	2.113	17.53	1.983	14.92	11.282	14.26	9.391	12.12
HPF	1.347	13.82	1.109	11.30	7.653	9.38	5.908	7.87




图6 事故情况下基于仿真数据的交通参数估计

Fig. 6 Estimation of traffic parameters based on simulation data under accident condition

的拟合情况也好于 EKF 和 UKF, 说明在发生事故产生较大交通流波动的情况下, HPF 表现出了较好的适应度, 仍可稳定地追踪交通流的变化。参数自适

应调整策略在事故情况下同样也产生了良好的效果,交通量和速度的曲线拟合程度明显略好于无参数自适应的情况,说明事故可能导致交通流发生波动的异常事件不会对参数自适应调整策略产生较大的干扰。

事故情况下3种方法的性能对比如表2所示,表中情况更加印证了上述曲线的分析结果。但由于受到交通事故的影响,交通参数在事故发生时段波动过大,使得表2中的估计准度相比于表1所示的正常情况略有下降。

表2 事故情况下基于仿真数据的EKF, UKF, HPF的性能比较

Tab.2 Comparison of properties of EKF, UKF and HPF based on simulation data under accident condition

参数	交通量				速度			
	无调整		调整后		无调整		调整后	
参数自适应调整								
性能指标	RMSE _a	RMSE _r / %	RMSE _a	RMSE _r / %	RMSE _a	RMSE _r / %	RMSE _a	RMSE _r / %
EKF	3.624	28.64	3.543	25.73	17.362	20.31	15.005	19.02
UKF	2.432	19.32	2.126	17.21	13.781	17.92	12.261	15.37
HPF	1.653	14.98	1.305	14.01	9.015	12.17	8.322	10.12

3 结论

(1) 基于混合粒子滤波的交通参数估计准确度明显高于卡尔曼滤波估计。在正常情况下和事故运行场景下,都能快速识别交通量和速度的较明显波动,说明基于混合粒子滤波的参数估计在应对交通场景的变化时表现出了更强的稳定性。

(2) 交通状态影响下的模型参数自适应调整策略对交通参数估计准确度具有显著影响。采用参数自适应调整后的估计效果明显好于无参数自适应调整的情况,即使在发生事故导致交通流异常波动的情况下,尽管准确度有所下降,但也达到了较好的估计效果。

(3) 当事故发生时,估计准确度会略有下降,说明估计准确度对异常交通参数波动较为敏感。在下一步的研究中,将深入分析事故持续时间和影响范围对估计准确度的影响。

参考文献:

References:

- [1] HERRERA J C, BAYEN A M. Incorporation of Lagrangian Measurements in Freeway Traffic State Estimation [J]. Transportation Research Part B: Methodological, 2010, 44 (4): 460-481.
- [2] VAN LINT J W C, HOOGENDOORN S P. A Robust and Efficient Method for Fusing Heterogeneous Data from Traffic Sensors on Freeways [J]. Computer-Aided Civil and Infrastructure Engineering, 2010, 25 (8): 596-612.
- [3] WANG Y, PAPAGEORGIOU M, MESSMER A, et al. An Adaptive Freeway Traffic State Estimator [J]. Automatica, 2009, 45 (1): 10-24.
- [4] WANG Y, PAPAGEORGIOU M, MESSMER A. RENAISSANCE: A Unified Macroscopic Model-based Approach to Real-time Freeway Network Traffic Surveillance [J]. Transportation Research Part C: Emerging Technologies, 2006, 14 (3): 190-212.
- [5] WANG Y, PAPAGEORGIOU M, MESSMER A. Real-time Freeway Traffic State Estimation Based on Extended Kalman Filter: A Case Study [J]. Transportation Science, 2007, 41 (2): 167-181.
- [6] 董春娇, 邵春福, 周雪梅, 等. 基于交通流参数相关的阻塞流短时预测卡尔曼滤波算法 [J]. 东南大学学报: 自然科学版, 2014, 44 (2): 413-419.
DONG Chun-jiao, SHAO Chun-fu, ZHOU Xue-mei, et al. Kalman Filter Algorithm for Short-term Jam Traffic Prediction Based on Traffic Parameter Correlation [J]. Journal of Southeast University: Natural Science Edition, 2014, 44 (2): 413-419.
- [7] ROMANENKO A, CASTRO J A A M. The Unscented Filter as an Alternative to the EKF for Nonlinear State Estimation: A Simulation Case Study [J]. Computers & Chemical Engineering, 2004, 28 (3): 347-355.
- [8] YE Z, ZHANG Y, MIDDLETON D R. Unscented Kalman Filter Method for Speed Estimation Using Single Loop Detector Data [J]. Transportation Research Record, 2006, 1968 (1): 117-125.
- [9] 程松, 陈光梦. 一种利用UKF的高速公路实时交通状态估计方法 [J]. 计算机工程与应用, 2008, 44 (8): 226-229.
CHENG Song, CHEN Guang-meng. Real-time Motorway Traffic State Estimation Based on Unscented Kalman Filtering [J]. Computer Engineering and Applications, 2008, 44 (8): 226-229.
- [10] MIHAYLOVA L, BOEL R, HEGYI A. Freeway Traffic Estimation within Particle Filtering Framework [J]. Automatica, 2007, 43 (2): 290-300.
- [11] MIHAYLOVA L, HEGYI A, GNING A, et al. Parallelized Particle and Gaussian Sum Particle Filters for Large-scale Freeway Traffic Systems [J]. IEEE Transactions on Intelligent Transportation Systems, 2012, 13 (1): 36-48.
- [12] WANG Y, PAPAGEORGIOU M. Real-time Freeway Traffic State Estimation Based on Extended Kalman Filter: a General Approach [J]. Transportation Research Part B: Methodological, 2005, 39 (2): 141-167.