

车联网通过两级量化自适应卡尔曼滤波实现车辆状态预测



冯安琪 钱丽萍 欧阳金源 吴远

浙江工业大学信息工程学院 杭州 310023

(aqfeng_zjut@163.com)

摘要 随着城市化和机动化的快速发展,交通安全越来越受到人们的关注。利用车载网络系统获取车载数据来预测车辆下一时刻的车载状态,对于提高运输路段的交通安全起着重要作用。文中提出一种基于自回归滑动平均(Auto-Regressive Moving Average, ARMA)模型的两级量化自适应卡尔曼滤波算法,来预测车辆的行车状态(行驶的方向、行驶的车道、车辆的速度和加速度)。首先,开发了一个车载网络系统,通过交换车载单元(On-Board Unit, OBU)和路边单元(Roadside Unit, RSU)之间的交通数据来获取车辆数据;然后,通过配置在路边单元的边缘云服务器来预测车辆状态;最后,边缘服务器把预测到的状态信息广播给其他路边单元,以便交叉口其他车辆获取车辆信息。实验结果验证了用于预测加速度的自回归移动平均模型的有效性。此外,文中还评估了所提算法的有效性。与其他3种预测算法相比,所提算法的速度预测精度分别提高了90.62%, 89.81%, 82.76%,这说明该算法在车载网络中能有效预测车辆状态。

关键词: 车载网络;交通安全;量化自适应卡尔曼滤波;自回归滑动平均模型;车辆状态预测

中图法分类号 TP391

Vehicular Networking Enabled Vehicle State Prediction with Two-level Quantized Adaptive Kalman Filtering

FENG An-qi, QIAN Li-ping, OUYANG Jin-yuan and WU Yuan

College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China

Abstract With the rapid development of urbanization and motorization, traffic safety issues have been drawing more and more attentions. The accurate prediction of vehicle state based on the data acquired by the vehicular networking system plays an important role in improving the traffic safety in transportation section. This paper proposes a two-level quantized adaptive Kalman filter algorithm (QAKF) based on the auto-regressive moving average (ARMA) model, to predict the vehicle state (i. e., the moving direction, driving lane, vehicle speed, and acceleration). First of all, a vehicular networking system is developed to acquire the vehicle data by exchanging traffic data among the on-board unit (OBU) and the roadside unit (RST). Then, the vehicle state is predicted at the edge cloud server equipped at the roadside unit. Finally, the edge cloud server broadcasts the predicted state to other roadside units for other vehicles at the intersection to obtain vehicle information. The numerical results verify the effectiveness of the auto-regressive moving average model used for predicting acceleration. And, this paper evaluates the efficiency of the proposed algorithm. Compared with the other three prediction algorithms, the proposed algorithm can improve the speed prediction accuracy by 90.62%, 89.81% and 82.76%, respectively, which implies that this algorithm can effectively predict the vehicle state in vehicular networks.

Keywords Vehicular networks, Traffic safety, Quantized adaptive Kalman filter, Auto-regressive moving average model, Vehicle state prediction

1 引言

随着城市化和机动化的快速发展,交通安全越来越受到人们的关注。根据世界卫生组织(WHO)的估计,全球每年有超过125万人死于交通意外^[1]。因此,提高道路交通安全,减

少交通事故的发生,具有十分重要的意义。目前,车联网因为能实现路边基础设施和行驶车辆之间的实时数据通信已经成为改善道路交通安全的有效解决方案之一^[2-7]。具体而言,车联网系统由传感单元、计算单元和智能控制单元组成,它们共同工作,收集交通状态数据,预测交通动态,并做出相应的

到稿日期:2019-03-29 返修日期:2019-10-21 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61379122);浙江省自然科学基金(LR16F010003)

This work was supported by the National Natural Science Foundation of China (61379122) and Natural Science Foundation of Zhejiang Province, China (LR16F010003).

通信作者:钱丽萍(lpqian@zjut.edu.cn)

控制决策,有效地提高了交通安全。

由于驾驶员的洞察能力有限,且交叉口通常是交通事故发生率较高的地方^[8],因此为了使驾驶员获得交叉口车辆的交通信息,避免潜在的事故发生,本文开发了一种车载网络系统,利用专用短程通信技术(Dedicated Short Range Communication, DSRC)^[9]实现车载单元与路边单元之间的交通数据通信,并通过边缘计算技术实现交通动态预测。首先,路边单元从车载单元中获取车辆的移动信息(如车辆位置、车辆速度等),并将车辆移动信息告知配备在路边单元的边缘云服务器;其次,边缘云服务器将车辆位置分级量化为行驶方向和驾驶车道,并依次对车辆的加速度和车速进行预测;然后,边缘云服务器通过光纤将处理后的车辆信息广播给其他路边单元;最后,行驶在交叉口的车辆通过其车载单元与相应路边单元的通信获取处理后的车辆信息。本文关注的是如何在路边单元配备的边缘云服务器上实现车辆状态预测,使驾驶员能够预估道路交通动态。

近年来,车辆状态预测引起了研究者们广泛的研究兴趣^[10-14]。文献[10]提出了一种基于多传感器融合技术的概率和整体车辆状态预测算法,用于估计当前车辆状态并预测未来状态。文献[11]提出了一种结合运动方程与卡尔曼滤波的动态目标追踪预测算法,实现对人员位置的预测和危险区域的预警。文献[12]提出了一种基于长短期记忆编码器-解码器结构的新型车辆轨迹分析和预测技术,用于分析过去轨迹中潜在的模式并生成未来的轨迹序列。文献[13]提出了一种射频识别环境下的基于自适应卡尔曼滤波的车辆速度预测方法,以实现高速移动车辆的速度预测。文献[14]研究了4种短期行驶速度预测模型,以满足基于蜂窝电话的交通数据环境,并采用时间序列概念进行速度预测。

本文在车联网环境下,提出了一种基于自回归移动平均模型的两级量化自适应卡尔曼滤波算法,该算法能够有效地对道路交通动态做出响应。首先,将车辆位置量化为行驶方向,确定路边单元的位置,进而将车辆位置量化为行驶车道;然后,利用自回归滑动平均模型预测车辆下一时刻的加速度;最后,将预测的车辆加速度作为自适应卡尔曼滤波模型的输入变量来预测下一时刻的车速。为了使车载系统在动态变化的交通环境中自适应地调整和更新数据,避免滤波器发散,本文在卡尔曼滤波模型中引入一个变量。该变量可以实时调整卡尔曼增益和先验误差协方差,从而消除历史数据,提高系统的滤波精度和实时性。

2 系统模型和问题建模

2.1 系统模型

在智能交通系统中,本文考虑一个车载网络,该网络由车载单元(安装于车内)、路边单元及其配备的边缘云服务器(位于红绿灯上)组成,如图1所示。此外,每个路边单元配备一个具有60°接收角的定向天线,以提供全扇区覆盖。车载单元和路边单元之间利用DSRC技术进行数据交换,交换过程如图2所示。边缘云服务器与其他路边单元之间通过光纤连接,减少了数据传播的延迟,提高了整个系统的数据传输效率。

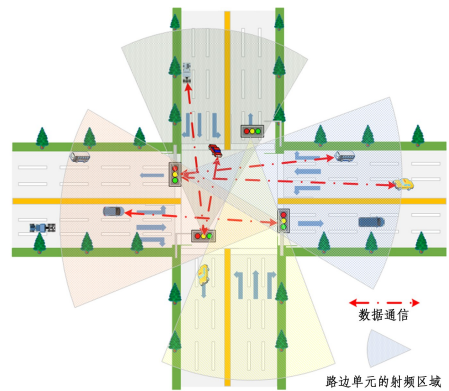


图1 车联网系统图

Fig. 1 Vehicular networking system

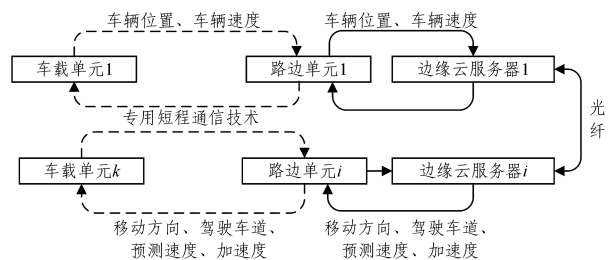


图2 车联网中车载信息交互图

Fig. 2 Vehicle information interaction in vehicular networking

交叉口的每个方向上都有一个路边单元,用 (x_i, y_i) 表示RSU i 的位置。假设这4个RSU独立运行,并通过光纤相互通信,以交叉口中心为坐标原点,用 $(x_k(t), y_k(t))$ 表示第 k 辆车在 t 时刻的位置。那么,当车辆 k 以 $v_k(t)$ 的速度移动到RSU的射频区域时,其OBU将利用DSRC技术将车辆位置 $(x_k(t), y_k(t))$ 和速度 $v_k(t)$ 通知给该RSU并将其转发到附加的边缘云服务器上。在 t 时刻,边缘云服务器预测车辆 k 的移动方向和行驶车道为 $b_k(t)$ 和 $c_k(t)$,并预测下一时刻车辆 k 的加速度和行驶速度。最后,边缘云服务器通过光纤将数据传播给其他路边单元。

2.2 问题建模

为了获得预测的车速、行驶方向和驾驶车道,将一个 n 维车辆状态方程建模为离散时间随机过程,因此其状态空间模型可表示为^[15-16]:

$$\mathbf{X}_k(t+1) = \mathbf{F}_k(t)\mathbf{X}_k(t) + \mathbf{G}_k(t)u_k(t) + \mathbf{H}_k(t)\omega_k(t) \quad (1)$$

$$Z_k(t) = \mathbf{L}_k(t)\mathbf{X}_k(t) + v_k(t), k=1, 2, \dots, K \quad (2)$$

其中, $\mathbf{X}_k(t)$ 为第 k 辆车在 t 时刻的状态向量,由位置 $(x_k(t), y_k(t))$ 和速度 $v_k(t)$ 组成; $\mathbf{F}_k(t)$ 为第 k 辆车在 t 时刻的状态转移矩阵; $\mathbf{G}_k(t)$ 为第 k 辆车在 t 时刻的输入向量; $u_k(t)$ 为车辆 k 在 t 时刻的加速度; $\mathbf{H}_k(t)$ 表示状态噪声矩阵; $Z_k(t)$ 为第 k 辆车在时刻 t 的真实观测值; $\mathbf{L}_k(t)$ 为第 k 辆车在时刻 t 的观测值矩阵; $\omega_k(t)$ 和 $v_k(t)$ 分别表示系统误差和观测误差,两者都是呈高斯分布的白噪声,分别服从 $N(0, \mathbf{Q})$ 和 $N(0, \mathbf{R})$ 分布。

3 车辆状态预测算法

本节提出一种两级量化自适应卡尔曼滤波算法来预测车辆的状态。其各个主要部分如下。

3.1 量化车辆位置

在射频区域,边缘云服务器从 RSU 接收车辆 k 在 t 时刻的位置 $(x_k(t), y_k(t))$ 和速度 $v_k(t)$, 并将位置信息转换为车辆实际方位角所呈现的数字信息^[15]。根据文献[17], 将车辆相对于 RSU 的实际方位角 $\theta_k(t)$ 定义为:

$$\theta_k(t) = z_k(\mathbf{X}_k(t)) + \varepsilon_k(t) \quad (3)$$

其中, $\varepsilon_k(t)$ 表示第 k 车辆在 t 时刻的零均值呈高斯白分布的方位误差噪声。 $z_k(\mathbf{X}_k(t))$ 是将位置信息转化为角信息的函数, 具体表示为:

$$z_k(\mathbf{X}_k(t)) = \begin{cases} \arctan\left(\frac{y_k(t)}{x_k(t)}\right), & x_k(t) > 0, y_k(t) > 0 \\ \arctan\left(\frac{y_k(t)}{x_k(t)}\right) + \pi, & x_k(t) < 0, y_k(t) > 0 \\ \arctan\left(\frac{y_k(t)}{x_k(t)}\right) + \pi, & x_k(t) < 0, y_k(t) < 0 \\ \arctan\left(\frac{y_k(t)}{x_k(t)}\right) + 2\pi, & x_k(t) > 0, y_k(t) < 0 \end{cases} \quad (4)$$

本文以交叉口中心为坐标原点, 根据实际方位角 $\theta_k(t)$, 驾驶方向量化如下:

$$b_k(t) = q(\theta_k(t)) = i, i \in \{1, 2, 3, 4\} \quad (5)$$

其中, $b_k(t)$ 为车辆 k 在 t 时刻的驾驶方向; i 为编号索引值; $q(\cdot)$ 为量化函数。其中, $i=1$ 表示车辆自东向西行驶; $i=2$ 表示车辆自西向东行驶; $i=3$ 表示车辆自南向北行驶; $i=4$ 表示车辆自北向南行驶。由此可以确定 RSU 的位置 (x_i, y_i) 。为了使方位信息更具体, 进一步量化行驶方向 $b_k(t)$ 从而获取驾驶车道。因此, 根据车辆与 RSU 之间的位置关系计算 $z_k(\mathbf{X}_k(t))$ 为:

$$z_k(\mathbf{X}_k(t)) = \arctan\left(\frac{y_k(t) - y_i}{x_k(t) - x_i}\right) \quad (6)$$

此后, 结合式(3)将驾驶车道进一步量化为:

$$c_k(t) = q(\theta_k(t)) = j, j \in \{1, 2, 3\} \quad (7)$$

其中, $c_k(t)$ 为车辆 k 在 t 时刻的驾驶车道; j 为编号索引值。我们假设驾驶员初期驾驶车辆在中间车道, 并且在时隙内只改变一个车道。因此, 当 $\theta_k(t) < 0$ 时表示车辆行驶在左车道, 记为 $j=1$; 当 $\theta_k(t) = 0$ 时表示车辆行驶在中间车道, 记为 $j=2$; 当 $\theta_k(t) > 0$ 时表示车辆行驶在右车道, 记为 $j=3$ 。

3.2 通过 ARMA 模型预测车辆加速度

为了在提高精度的同时更好地预测下一时刻的车辆状态, 文中引入了一个中间变量(即加速度 $a_k(t)$)。加速度采用自回归滑动平均模型计算, 公式如下:

$$a_k(t) = \sum_{l=1}^p \beta_l a_k(t-l) + \sum_{m=1}^q \varphi_m \xi_k(t-m) + \xi_k(t) \quad (8)$$

其中, $a_k(t)$ 是车辆 k 在 t 时刻的加速度, 即利用时间序列的前期加速度进行预测; p 表示自回归模型(Auto Regressive, AR)的阶数, 即加速度总数; q 表示滑动平均模型(Moving Average, MA)的阶数, 即滑动总数; β_l 表示第 l 阶的自回归系数; φ_m 表示滑动平均系数; $\xi_k(t)$ 是车辆 k 在 t 时刻呈高斯分布的白噪声。具体地, 前期加速度 $a_k(t-l)$ 的计算公式如下:

$$a_k(t-l) = \frac{v_k(t-l+1) - v_k(t-l)}{\tau_k(t-l+1) - \tau_k(t-l)} = \frac{\Delta v_k}{\Delta \tau_k}, l=1, 2, \dots, p \quad (9)$$

其中, Δv_k 表示第 k 辆车中两个相邻时间的速度差; $\Delta \tau_k$ 表示第 k 辆车的采样时间间隔。

本文基于 ARMA 模型实现了两级量化自适应卡尔曼滤波算法, 其中 ARMA 模型由以下 4 个关键要素构建^[18]。

(1)数据收集: 从 RSU 中获取一个有限集的车辆信息 $\{\mathbf{X}_k(t)\}_{t=0}^{T-1}$ 。

(2)数据处理: 对采集到的车辆速度进行处理, 用以计算车辆以前的加速度, 即式(9)。

(3)模型辨识: AR 和 MA 相关部分的阶数由自相关函数(ACF)和互相关函数(PACF)决定, 即确定 p 和 q 的值。如果 ACF 呈指数衰减或正弦衰减, 并且 PACF 在 n 阶之前显然不是 0, 然后突然接近或等于 0, 那么我们设 $p=n, q=0$; 如果 PACF 呈指数衰减或正弦衰减, 并且 ACF 在 n 阶之前显然不是 0, 然后突然接近或等于 0, 那么我们设 $p=0, q=n$; 如果 ACF 和 PACF 都呈指数或正弦衰减, 那么 q 和 p 的值分别对应其峰值。然而, ACF 和 PACF 获得的模型形式不是唯一的, 因此, 本文采用最小赤池信息准则(AIC)和贝叶斯信息准则(BIC)进一步确定模型阶数。

(4)优化与选择: 首先, 根据最小 AIC 准则和最小 BIC 准则分别确定 AR 模型和 MA 模型的阶数; 其次, 使用历史数据来计算确定的 ARMA 模型的系数, 这样有利于避免过拟合现象。

本文中, 确定的 ARMA 模型将直接预测车辆的加速度; 同时, 通过式(8)来调整模型的原始参数, 并预测最新的加速度用于车辆状态的预测。

3.3 预测车辆状态

本节基于预测加速度 $a_k(t)$ 和车辆状态 $X_k(t)$, 利用 QAKF 对车辆状态进行预测。该算法具体由两部分组成: 预测部分和更新部分。

假定在 t 时刻状态 $\hat{\mathbf{X}}_k(t) = E\{\mathbf{X}_k(t)\}$ 和误差协方差 $\hat{\mathbf{P}}_k(t) = E\{(\mathbf{X}_k(t) - \bar{\mathbf{X}}_k(t))(\mathbf{X}_k(t) - \bar{\mathbf{X}}_k(t))^T\}$ 是已知的, 那么该算法的步骤如下。

步骤 1 预测车辆状态

$$\tilde{\mathbf{X}}_k(t+1) = \mathbf{F}_k(t)\hat{\mathbf{X}}_k(t) + \mathbf{G}_k(t)a_k(t) + \mathbf{H}_k(t)\omega_k(t) \quad (10)$$

其中, $\tilde{\mathbf{X}}_k(t+1)$ 表示状态 $\mathbf{X}_k(t+1)$ 在 $t+1$ 时刻的先验估计, 即预测值; $\hat{\mathbf{X}}_k(t)$ 表示状态 $\mathbf{X}_k(t)$ 在 t 时刻后验估计, 即更新后的值。

步骤 2 计算新息

$$\mathbf{e}_k(t) = \mathbf{Z}_k(t+1) - \mathbf{L}_k(t+1)\tilde{\mathbf{X}}_k(t+1) \quad (11)$$

步骤 3 计算自适应遗忘因子

$$\lambda_k(t+1) = \max\left\{1, \frac{\mathbf{N}_k(t+1)}{\mathbf{M}_k(t+1)}\right\} \quad (12)$$

$$\mathbf{N}_k(t+1) = \mathbf{C}_k(t+1) - \mathbf{L}_k(t+1)\mathbf{Q}\mathbf{L}_k^T(t+1) - \mathbf{R} \quad (13)$$

$$\mathbf{M}_k(t+1) = \mathbf{L}_k(t+1)\mathbf{F}_k(t+1)\hat{\mathbf{P}}_k(t)\mathbf{F}_k^T(t+1)\mathbf{L}_k^T(t+1) \quad (14)$$

$$\mathbf{C}_k(t+1) = \begin{cases} \mathbf{e}_k(t+1)\mathbf{e}_k^T(t+1), & t=p \\ \frac{\rho\mathbf{C}_k(t) + \mathbf{e}_k(t+1)\mathbf{e}_k^T(t+1)}{1+\rho}, & t>p \end{cases} \quad (15)$$

其中, ρ 表示满足 $\rho \in (0, 1)$ 的正参数; T 表示矩阵的转置; $C_k(t+1)$ 表示新息在 $t+1$ 时刻的协方差; Q 和 R 分别表示 $\omega_k(t)$ 和 $\nu_k(t)$ 的协方差矩阵; $\hat{P}_k(t)$ 表示在 t 时刻后验误差的协方差。注意, Q, R 和 $\hat{P}_k(t)$ 都是正定对称矩阵。

步骤 4 预测误差协方差

$$\tilde{P}_k(t+1) = \lambda_k(t+1) F_k(t) \hat{P}_k(t) F_k^T(t) + H_k(t) Q H_k^T(t) \quad (16)$$

其中, $\tilde{P}_k(t+1)$ 表示 $t+1$ 时刻的先验误差协方差。

步骤 5 更新卡尔曼增益

$$B_k(t+1) = (L_k(t+1) \tilde{P}_k(t+1) L_k^T(t+1) + R)^{-1} \quad (17)$$

$$\hat{K}_k(t+1) = \tilde{P}_k(t+1) L_k^T(t+1) B_k(t+1) \quad (18)$$

其中, $\hat{K}_k(t+1)$ 表示车辆 k 在 t 时刻的卡尔曼增益, 随着 $\lambda_k(t+1) \hat{P}_k(t)$ 的变化而变化。

步骤 6 更新车辆状态

$$\hat{X}_k(t+1) = \tilde{X}_k(t+1) + \hat{K}_k(t+1) e_k(t+1) \quad (19)$$

步骤 7 更新误差协方差

$$\hat{P}_k(t+1) = [I - \hat{K}_k(t+1) L_k(t+1)] \tilde{P}_k(t+1) \quad (20)$$

在传统的卡尔曼滤波算法中, 卡尔曼增益 $\hat{K}_k(t+1)$ 和新息 $e_k(t+1)$ 之间没有直接的影响。随着新息 $e_k(t+1)$ 的增加, 卡尔曼增益 $\hat{K}_k(t+1)$ 不会增加, 这意味着无法实时跟踪过滤器, 且当发生突变状况时无法及时跟进。为了解决这个缺点, 本文在式(15)中引入了新息的协方差 $C_k(t+1)$; 在式(12)中引入自适应遗忘因子 $\lambda_k(t+1)$; 通过式(16)和式(18)分别实时调整先验误差协方差 $\hat{P}_k(t+1)$ 和卡尔曼增益 $\hat{K}_k(t+1)$ 。特别地, $\lambda_k(t+1) \geq 1$ 保证了在更新部分测量值比预测值更具优势。本文进行以上操作是为了使更新后的值更接近测量值。

此后, 边缘云服务器通过光纤将预测的车辆状态广播给其他 RSU, 实现交叉口各方位上车辆信息的交互, 降低交通事故发生率。

4 实验设计与结果分析

4.1 实验设置

本文采用 MATLAB 进行仿真实验, 以评估所提出的车

辆状态预测算法的准确度。实验数据来源于法国 Val de Marne 总部(94)收集的位于法国 Creteil 地区复杂环形交叉口的数据^[19-20]。该数据集提供的是上午 7 时至上午 9 时, 下午 5 时至下午 7 时的数据。该时间段为车流的高峰期, 车辆状态随机变化概率大, 车辆密度增加, 意外状况多, 驾驶员能反应的时间短。故此, 为了提高道路的安全性以及预测车辆状态的准确性, 本文采用高峰期的数据来验证所提算法的有效性。在仿真实验中, 时间间隔设为 1 s。

4.2 确定 ARMA 模型的阶数

由于 ARMA 模型的阶数(即 p 和 q)在一开始是未知的, 因此需要在执行所提算法之前获取 p 和 q 的值, 以便预测车辆加速度。

为了找到一个适用于任何交通环境的 ARMA 模型, 文中根据不同的时间周期和不同的初始状态进行仿真实验。首先, 计算 ACF 和 PACF 值, 如图 3 所示。其中, 图 3(a)使用的是早上 7:00 至早上 9:00 的交通数据, 且车辆从静止状态变化到高速运行状态; 图 3(b)使用的是早上 7:00 至早上 9:00 的数据, 但车辆始终处于高速运行状态; 图 3(c)使用的是晚上 17:00 至 19:00 的数据, 车辆从静止状态变化到高速运行状态。

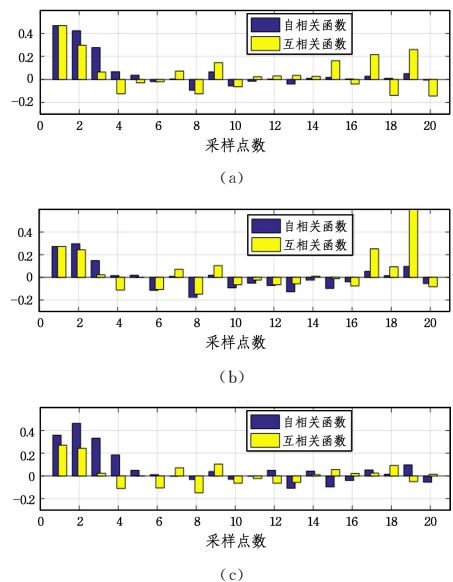


图 3 不同场景下的 ACF 和 PACF 值

Fig. 3 ACF and PACF values in different scenarios

表 1 不同场景下的 AIC 和 BIC 值

Table 1 AIC and BIC values in different scenarios

	AIC				BIC			
图 3(a)	180.6704	182.4831	177.8900	177.0186	186.4065	190.1312	187.4501	188.4907
	177.7765	176.3084	184.0809	176.7979	185.4245	185.8685	195.5530	190.1821
	174.9297	176.7583	185.7101	176.7052	184.4898	188.2304	199.0943	192.0013
	176.7795	175.8383	176.7844	178.1213	188.2517	189.2225	192.0805	195.3295
图 3(b)	171.2136	171.5561	171.5561	171.7478	176.9497	179.2042	183.1158	183.2199
	171.8997	173.4582	171.9345	173.9312	179.5478	183.0184	183.4067	187.3154
	169.6657	171.5834	173.5552	171.9137	179.2258	183.0556	186.9394	187.2099
	170.8759	169.4588	171.3314	173.3110	182.3480	182.8430	186.6276	190.5192
图 3(c)	168.0402	167.8965	165.5700	165.1505	173.7763	175.5446	175.1301	176.6227
	169.4764	169.7453	165.1537	166.6069	177.1245	179.3055	176.6259	179.9911
	163.6432	165.0177	166.8177	167.5023	173.2033	176.4899	180.2018	182.7985
	164.4572	166.4469	168.0666	169.4206	175.9294	179.8311	183.3628	186.6288

从图 3 中可以看到, ACF 和 PACF 均在采样点数 4 之前显然不为 0, 然后突然接近或等于 0。因此, 本文设置 $p_{\max} = 4$ 和 $q_{\max} = 4$, 并在此范围内计算 AIC 和 BIC 值, 分别得到一个 4×4 的维度矩阵如表 1 所列。如果通过 AIC 方法生成的矩阵中最小值的行、列位置与 BIC 方法生成的矩阵中最小值的行、列位置相同, 则将该位置(行和列)分别记录为 AR 模型和 MA 模型的阶数。由表 1 可知, 计算得到的 AIC 和 BIC 在第 3 行第 1 列的数值为最小值, 虽然表图 3(b) 中数据所生成的 BIC 矩阵在第 1 行第 1 列为最小值, 但结合多组数据以及 3.2 节生成 ARMA 模型的关键要素(2)中数据处理所产生的误差, 我们选择 ARMA(3,1) 模型作为加速度预测模型, 即 $p = 3$ 和 $q = 1$ 。

4.3 评估提出算法的有效性

本文采用平均绝对误差(MAE)和平均绝对百分比误差(MAPE)来评价本文提出的车辆状态预测算法的有效

性, MAE 和 MAPE 的公式如下:

$$MAE = \frac{\sum_{t=p}^{T-1} |\hat{\mathbf{X}}_k(t+1) - \mathbf{Z}_k(t+1)|}{T-p} \quad (21)$$

$$MAPE = \frac{1}{T-p} \sum_{t=p}^{T-1} \frac{|\hat{\mathbf{X}}_k(t+1) - \mathbf{Z}_k(t+1)|}{\mathbf{Z}_k(t+1)} \times 100\% \quad (22)$$

其中, $T-p$ 为观测总数; $\hat{\mathbf{X}}_k(t+1)$ 表示第 k 辆车在 $t+1$ 时刻预测后的修正值; $\mathbf{Z}_k(t+1)$ 表示第 k 辆车在 $t+1$ 时刻的实际值。

本文采用自回归滑动平均模型(ARMA)、卡尔曼滤波(KF)和无迹卡尔曼滤波(UKF) 3 种预测算法为基准, 对提出的算法进行对比。实验使用统一的数据集(图 3(c) 使用的数据)和确定的 ARMA(3,1) 模型来预测车辆加速度, 并将预测的加速度作为各模型的时变输入来预测车辆状态。图 4 为同一数据集下 4 种不同算法的速度预测结果。

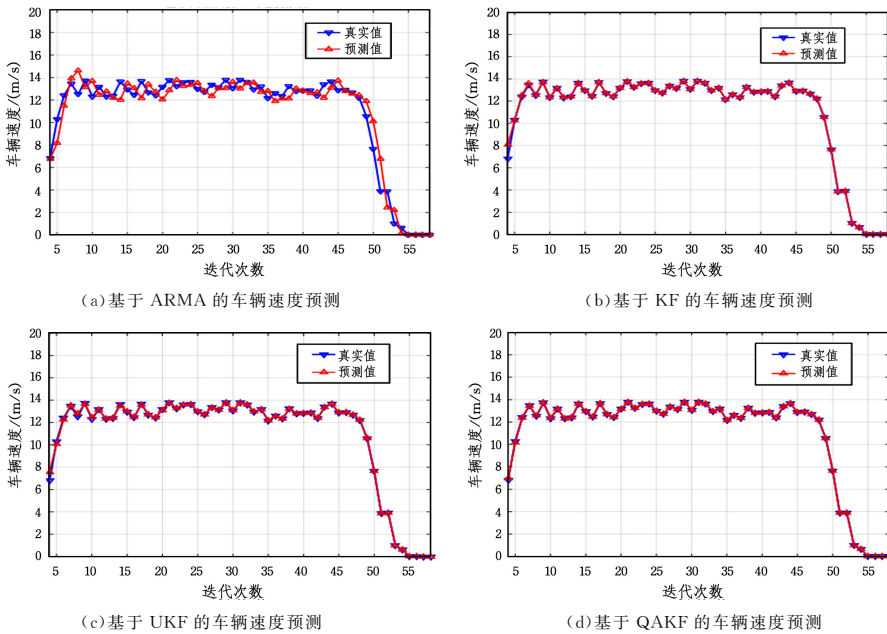


图 4 同一数据集下 4 种不同算法的速度预测结果

Fig. 4 Speed prediction results of four different algorithms under the same data set

从图 4 可以看出, 随着迭代次数的增加, 实际值与预测值之

间的差值逐渐减小。各算法对速度预测的具体误差如图 5 所示。

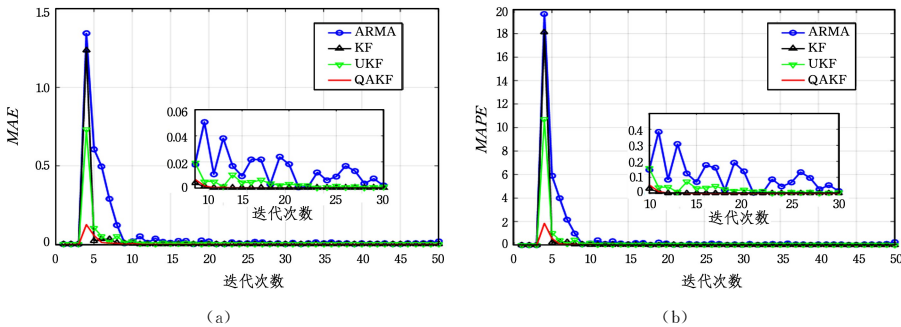


图 5 同一数据集下 4 种不同算法的速度预测误差

Fig. 5 Speed prediction errors of four different algorithms under the same data set

从图 5 可以看出, 除了算法 ARMA 外, 各算法的预测误差基本为 0, 即经过 10 次迭代后均可收敛。这是因为与 KF, UKF 和 QAKF 算法相比, ARMA 没有滤波阶段。从图 5 还可以看出算法 QAKF 的误差值最小, 与 ARMA, KF 和 UKF

3 种算法相比具体的速度预测精度分别提高了 90.62%, 89.81% 和 82.76%。

由于在某个时刻进入 RSU 覆盖范围内的车辆数量是随机的, 本文在不考虑车辆数量对数据传输的影响下, 假设每辆

车传输至边缘云服务器的数据都是正确无误的。在此,本文评估了RSU覆盖范围内有4辆、8辆、12辆、16辆以及20辆车时,QAKF算法对车辆状态预测的影响,其平均误差结果如图6所示。可以看到,不同的车辆数量对于所提出的车辆状态预测算法的性能影响不大。




图6 不同车辆数量下QAKF算法的平均预测误差

Fig. 6 Average prediction error of QAKF algorithm under different vehicle numbers

结束语 本文开发了一种车联网系统,通过交换车载单元和相应路边单元之间的数据来互相获取车辆数据。本文还提出了一种基于自回归移动平均模型的两级量化自适应卡尔曼滤波算法,用以预测车辆状态。实验结果表明,所提出的车辆状态预测算法在预测精度方面优于其他3种预测算法。在未来,我们将考虑RSU覆盖范围内车辆数量对数据传输的影响以及数据丢失对车辆状态预测的影响。

参考文献

- [1] WHO. Deaths on the roads; based on the WHO global status report on road safety 2015[M]. World Health Organization (WHO), 2015.
- [2] CHENG N, LYU F, CHEN J Y, et al. Big data driven vehicular networks[J]. IEEE Network, 2018, 32(6): 160-167.
- [3] QIAN L P, WU Y, ZHOU H B, et al. Dynamic cell association for non-orthogonal multiple-access V2S networks [J]. IEEE Journal on Selected Areas in Communications, 2017, 35(10): 2342-2356.
- [4] TAKAHASHI Y, KAWAMOTO Y, NISHIYAMA H, et al. A novel radio resource optimization method for relay-based unmanned aerial vehicles[J]. IEEE Transactions on Wireless Communications, 2018, 17(11): 7352-7363.
- [5] SUN Y L, XU Y, TANG Y L, et al. Traffic offloading for online video service in vehicular networks: a cooperative approach[J]. IEEE Transactions on Vehicular Technology, 2018, 67(8): 7630-7642.
- [6] BHARATI S, ZHUANG W H, THANAYANKIZIL L V, et al. Link-layer cooperation based on distributed TDMA MAC for vehicular networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(7): 6415-6427.
- [7] LIU K, FENG L, DAI P L, et al. Coding-assisted broadcast scheduling via memetic computing in SDN-based vehicular networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(8): 2420-2431.
- [8] RASHDAN L, SCHMIDHAMMER M, MUELLER F P, et al. Performance evaluation of vehicle-to-vehicle communication for cooperative collision avoidance at urban intersections[C]// IEEE 86th Vehicular Technology Conference (VTC-Fall). 2017: 1-5.
- [9] HAFEEZ K A, ANPALAGAN A, ZHAO L. Optimizing the control channel interval of the DSRC for vehicular safety applications[J]. IEEE Transactions on Vehicular Technology, 2016, 65(5): 3377-3388.
- [10] KIM B, YI K. Probabilistic and holistic prediction of vehicle states using sensor fusion for application to integrated vehicle safety systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 2178-2190.
- [11] WANG Y, DENG Q X, LIU G H, et al. Dynamic target tracking and predicting algorithm based on combination of motion equation and Kalman filter[J]. Computer Science, 2015, 42(12): 76-81.
- [12] PARK S, KIM B, KANG C, et al. Sequence-to-sequence prediction of vehicle trajectory via LSTM encoder-decoder architecture [C]// IEEE Intelligent Vehicles Symposium (IV). 2018: 1672-1678.
- [13] FENG A Q, QIAN L P, HUANG Y P, et al. RFID data driven vehicle speed prediction using adaptive Kalman filter [J]. Computer Science, 2019, 46(4): 100-105.
- [14] BASYONI Y, ABBAS H M, TALAAT H, et al. Speed prediction from mobile sensors using cellular phone-based traffic data [J]. IET Intelligent Transport Systems, 2017, 11(7): 387-396.
- [15] HU X, BAO M, ZHANG X, et al. Quantized Kalman filter tracking in directional sensor networks[J]. IEEE Transactions on Mobile Computing, 2018, 17(4): 871-883.
- [16] HU X, BAO M, ZHANG X, et al. Generalized iterated Kalman filter and its performance evaluation[J]. IEEE Transactions on Signal Processing, 2015, 63(12): 3204-3217.
- [17] RAHIMI A, DUNAGAN B, DARRELL T. Tracking people with a sparse network of bearing sensors[C]// Computer Vision (ECCV 2004). Heidelberg: Springer, 2004: 507-518.
- [18] WANG X W, SHEN X L, LIU X S. Random error analysis of MEMS gyroscope based on adaptive Kalman filter[J]. Chinese Journal of Sensors and Actuators, 2017, 30(11): 1666-1670.
- [19] LEBRE M, MOUEL F, MENARD E. On the importance of real data for microscopic urban vehicular mobility trace[C]// International Conference on ITS Telecommunications. 2015: 22-26.
- [20] LEBRE M, MOUEL F, MENARD E. Partial and local knowledge for global efficiency of urban vehicular traffic[C]// IEEE 82nd Vehicular Technology Conference. 2015: 1-5.



FENG An-qi, born in 1995, postgraduate. Her main research interests include network and intelligent systems, vehicular networking and Internet of Things technologies.



QIAN Li-ping, born in 1981, Ph.D., professor, Ph.D supervisor, is a member of China Computer Federation. Her main research interests include wireless communication network, vehicular networking and Internet of Things technologies.