

# 高通讯时延下融合车道级地图的车路协同感知定位方法\*

胡钊政<sup>1,2</sup>, 胡华桦<sup>1,2</sup>, 孟杰<sup>1,2,3</sup>, 陈琪莉<sup>1,2</sup>, 张佳楠<sup>1,2</sup>

(1. 武汉理工大学智能交通系统研究中心, 武汉 430063; 2. 武汉理工大学重庆研究院, 重庆 401120;  
3. 武汉理工大学, 交通物联网技术湖北省重点实验室, 武汉 430063)

**[摘要]** 在车路协同技术运用于路侧孪生地图动态显示中, 由于网联设备之间的通讯存在的时延问题及路侧感知误差的存在, 对路侧边缘计算单元融合感知精度会产生严重影响, 进而导致孪生地图中车辆显示轨迹出现抖动和延迟的现象。为此, 本文提出了一种在高通讯时延下融合车道级地图的车路协同感知定位方法。该方法首先针对车路协同系统中智能网联汽车车端与路侧边缘处理单元之间的通讯时延问题进行分析建模, 将延迟模型划分为异构传感器频率同步延迟以及通讯传输延迟, 并提出了一种同步优化方法。在同步优化后, 提出一种面向群车协同的多维度群车粒子滤波算法, 其中粒子的状态量表示群车的状态信息。在所提出的多维度群车粒子滤波算法中首先使用利用路侧部分的观测数据和车道级地图中车道线朝向信息, 对粒子的状态进行观测更新。然后利用接收到时延同步后的智能网联汽车的自定位信息和左右车道线横向观测信息与车道级地图中车道线方程对粒子中表示智能网联汽车状态的部分进行观测更新。实验结果显示, 在通讯干扰较少的低时延场景中, 边缘计算单元的感知定位准确度提升 59.4%, 在通讯干扰严重的高时延场景中, 其准确度提升 38.6%。因此所提出高通讯时延下融合车道级地图的车路协同感知定位方法可以有效处理通讯延时间题, 并提升边缘计算单元多车感知定位精度进而提升孪生地图动态数据的准确性、稳定性和连续性。

**关键词:** 时延同步; 车路协同; 车道级地图; 粒子滤波

## Vehicle-Road Cooperative Perception and Localization Method with High-Definition Map Under High Communication Delay

Hu Zhaozheng<sup>1,2</sup>, Hu Huahua<sup>1,2</sup>, Meng Jie<sup>1,2,3</sup>, Chen Qili<sup>1,2</sup> & Zhang Jianan<sup>1,2</sup>

1. ITS Research Center, Wuhan University of Technology, Wuhan 430063;  
2. Chongqing Research Institute of Wuhan University of Technology, Chongqing 401120;  
3. Wuhan University of Technology, Hubei Key Laboratory of Transportation Internet of Things, Wuhan 430063

**[Abstract]** In the application of vehicle-road cooperative technology for dynamic display of the roadside twin maps, due to the delay problem of the communication between networked devices and the existence of the roadside perception error, the fusion perception accuracy of the roadside edge computing unit will be seriously affected, which will lead to the jitter and delay of the vehicle display track in the twin map. Hence, in this paper a vehicle-road cooperative sensing and localization method that fuses high definition map under high communication delay is proposed. The method first analyzes and models the communication delay between the vehicle end of the connected vehicle and the roadside edge processing unit in the vehicle-road cooperative system, divides the delay model into sensor synchronization delay and communication transmission delay, and proposes a synchronization optimization method for the delay. After the synchronization optimization, a collaborative multidimensional particle filter algo-

\* 国家重点研发计划项目(2022YFB2502904)、湖北省重点研发计划项目(2022BAA082)、重庆市科技创新重大研发项目(CSTB2020TIAD-STX0003)和武汉市人工智能创新专项(2022010702040064)资助。

原稿收到日期为 2024 年 04 月 03 日, 修改稿收到日期为 2024 年 05 月 21 日。

通信作者: 孟杰, 博士, 副研究员, E-mail: mengjie09@whut.edu.cn。

rithm for swarm vehicles is proposed, where the states of the particles represent the pose of different connected vehicles and non-connected vehicles in the swarm vehicles. In the proposed multidimensional particle filter algorithm, the state of the particles is firstly updated using the observation of the state of the particles by utilizing the roadside RSU observation data and the curvature information of the lanes in the high-definition map. Then the self-localization information of the received delayed synchronized smart connected cars combined with the left and right lane line lateral constraint information and the lane line equations of the lanes in the high definition map are used to update the observation of the state portion of the particle that represents the smart connected cars. The experimental results show that the perceptual and localization accuracy of the edge server is improved by 59.4% in the low delay scenario with less communication interference, and its accuracy is improved by 38.6% in the high delay scenario with severe communication interference. Therefore, the proposed vehicle-road cooperative sensing method incorporating high definition map under high communication delay can effectively deal with the communication delay problem and improve the multi-vehicle perception accuracy of the edge computing unit, thus improving the accuracy, stability and continuity of the twin map dynamic data.

**Keywords:** time-delay synchronization; vehicle-road coordination; HD map; particle filter

## 前言

随着汽车工业、边缘计算、移动通讯等关键技术的不断发展,在交通领域中,车路协同作为车辆自动驾驶的关键技术整合落地实现方案,引起了国内外专家学者的广泛关注<sup>[1-2]</sup>。车路协同是以行驶中的车辆为主体,借助先进的信息通讯技术,实现车-车、车-路等之间的实时通讯,补全单车智能因传感范围不足而缺失的信息,提升智能网联车自动驾驶感知能力,提升交通运行效率<sup>[3]</sup>。借助车路协同智能网联通讯技术,将智能网联汽车的高精度自定位观测数据通过车载 OBU 设备发送路侧 RSU 设备,进而在边缘计算单元进行融合,可以有效提升路侧边缘计算单元多车感知定位精度。这种高精度的多车定位数据既可以用来生成该区域孪生地图场景用于上级交管部门实时监管该路段区域车辆的实时动态轨迹,也可以生成一种局部动态地图发送给该区域自动驾驶车辆增强其感知信息。

借助车路协同框架,在路侧边缘计算单元对于车端和路侧部分的信息进行融合汇总。但由于通讯时延的存在,智能网联汽车车端数据通过这在 OBU 设备发往路侧 RSU 设备时会存在延迟,导致路侧边缘计算单元接收汇总表示智能网联汽车车辆轨迹的数据存在延迟和抖动的影响,对于之后的多传感器数据融合方面有不利的影响,导致孪生地图中多个车辆的轨迹存在延迟停滞的现象,而路侧相关观测存在误差过大则会导致车辆轨迹存在抖动的现象。

针对车路通讯时延问题,在通讯理论研究领域内常见的方法是使用一系列独立的伯努利变量序列来描述时滞问题。Moayed 等<sup>[5]</sup>针对传感器网络和网络控制系统的状态估计问题,提出了一种混合不确定性随机测量延迟、包丢失和测量丢失的自适应滤波方案。Ma 等<sup>[6]</sup>对于随机传感器延迟、包丢失和不确定观测值的线性离散时间随机系统的最优线性估计问题,设计了一种仅依赖于概率的最优线性估计方法。但以上研究大部分的延时都是基于已知发生延时的概率上,类似一种对于一段历史数据的分析评估方法,不适用于实际工程应用。在车路通讯时延工程应用方面,邱威智等<sup>[7]</sup>在考虑车路协同通讯时延的前提下,利用卡尔曼滤波,融合多尺度更新方法,在未接收到观测值的时刻,以原有状态转移方法进行更新。在收到观测值后,将观测值同步至延时前的时刻,并进行数据融合更新。之后在接收到下一观测值之前,以另一尺度进行状态转移,在孪生测试方面,达到了良好的效果。但所输出观测值为人定义的无误差的真值,无法应用于实际工程应用中。闵海根等<sup>[8]</sup>基于车路协同中的通讯时延进行大量真实传输实验测试,根据实验结果拟合出使用瑞利分布进行延迟模型搭建的更加合理,并将时延同步结果放入了所提出的双层滤波定位模型,提高了车辆的连续稳定的高精度定位信息,但在其模型的设定中多车均为配置了高精度定位装置的智能车辆,实际车路协同场景中多为智能网联汽车和非智能网联汽车混合行驶。张红娟等<sup>[9]</sup>采用因子图将当前时刻的车载惯性测量单元 IMU (inertial

measurement unit)测量信息和滞后的路侧目标定位结果直接融合,基于增量平滑推理方法,实现车辆位置、速度和姿态的最优估计,同样没有考虑多种车混合行驶的场景。

当前行业内对于高精度地图的定义并不统一,刘经南等<sup>[10]</sup>按照数据逻辑划分为4层:静态数据层、实时数据层、动态数据层和用户模型层。其中静态数据层主要包含道路网、车道网、交通设施与定位图层以提供丰富的道路语义信息约束与控制车辆行为。Jiang等<sup>[11]</sup>基于自动驾驶车辆提出了一种7层地图模型,囊括了自动驾驶各个环节所需的不同道路信息。而在融合地图信息方面中,基于道路网、车道网等信息进行了大量的研究。Xu等<sup>[12]</sup>提出了一种基于道路几何形状的定位方法,将车辆动力学和道路几何形状结合,以达到在GNSS(global navigation satellite system)信号缺失后车辆的定位。Zhang等<sup>[13]</sup>提出了一种基于3D地图融合GNSS的定位方法,通过对基于射线跟踪的3D地图辅助GNSS与双差分技术的互补集成,既消除了GNSS的系统误差,又减少了随机误差,提高了定位的精度。但所建3D激光地图数据量大,不易存储。Valgren等<sup>[14]</sup>提出了一种基于车道级地图的定位方法,将道路标记的边缘与投影地图对齐,将其转化为非线性优化的定位问题。邓泽武等<sup>[15]</sup>提出了一种融合激光雷达的双层高精地图定位方法,在搭建好车道级地图和特征地图的基础上,首先利用车道级地图获取横向距离约束,然后使用特征地图获取的绝对位姿进行融合定位。但上述文献中大部分所用地图数据量大、相关概念冗余,当前自动驾驶领域在逐渐地“去地图”,但“去地图”并不是无地图而是“轻地图”,如何使用一种轻量级的地图做到更好的感知效果逐渐成为当前研究热点,且对于车路协同相关融合应用较少。在上述研究的基础上,本文提出将车道级地图作为一种特殊的传感器,将它的车道线方程朝向信息和方程信息融入本文的多维度群车粒子滤波算法中,提升路侧孪生地图的感知定位精度。其中孪生地图是高精度地图中动态数据层面的应用,实际上也可以称作局部区域的动态地图。

路侧RSU(road side unit)设备可以通过搭载在其上的图像、激光雷达等传感器检测识别通过该路段区域的移动目标,通过计算处理后,提取移动目标的轨迹,获得车辆的路侧端观测数据。张小俊等<sup>[16]</sup>针对V2X(vehicle-to-X)中的路侧感知单元在检测

中模型部署困难等问题,提出了一种基于YOLOv7算法的轻量级检测算法,YOLOv7-R在满足轻量化要求的同时得到更优的检测精度。徐国艳等<sup>[17]</sup>提出了一种基于SVM(support vector machine)分类器改进了Adaboost算法,对三维激光点云进行直接处理,最大限度保留了感知信息,提高了识别准确度,有效提高了复杂交通流中目标跟踪的稳定性和准确性。Huang等<sup>[18]</sup>提出了一种基于相机和激光雷达融合的检测跟踪框架,该框架集检测和跟踪于一体,将图像和点云数据分别送入候选区域并提取网络获得各自的区域特征,然后对特征融合后分别输入目标检测网络和目标关联网络,数据关联使用运动相似度和外观信息的代价函数实现。但是单纯的路侧激光雷达跟踪检测该区域车辆的移动信息存在误差,导致在孪生场景中车辆会出现跳动,因此须利用车路协同智能网联通信技术来融合高精度的智能网联车端自定位数据与车道级地图数据来提升孪生场景中车辆的跳动现象。

在当前车路协同系统的设计中,边缘处理单元会接收运算处理车端路侧传输的传感器观测信息,来分担系统中的算力。基于此,在前面研究的基础上,针对车路协同背景下边缘计算单元感知更新的孪生地图中车辆轨迹显示的问题,本文提出了一种高通讯时延下融合车道级地图的车路协同感知定位方法。它的新颖之处在于:(1)针对车路协同中网联系统的通讯时延问题进行模型构建并提出了一种同步方法。(2)提出了一种多维度群车粒子滤波算法框架,该框架可以有效地融合多个传感器的观测数据,并将粒子的维度和车辆数量结合在一起,这种方法的优越性在于用一个观测矩阵来约束不同车辆的状态,这样既可以对单车的状态进行更新也对未来车车通信约束预留接口。(3)将车道级地图作为一种特殊的传感器输出车道线的朝向信息和车道线方程位置信息。将地图以一种轻量、简单、高效的方式融入所提出的多维度群车粒子滤波算法框架中。

## 1 高通讯时延下融合车道级地图的车路协同感知定位算法

本文提出的高通讯时延下融合车道级地图的车路协同感知定位方法的具体算法流程如图1所示。整个系统由两部分组成,分别是构成系统的多源异构传感器数据输入部分以及所提出的面向群车协同

的多维度群车粒子滤波算法。在车路协同网联系统不同设备的通讯中时延包括了同步时延、传播时延和算法的处理时延。其中同步时延是对于不同传感器设备之间的时间戳不同步产生的时延,而传输时延是信号在通讯链路中因为波动等其它原因产生的延时,处理时延是相关算法对于其数据进行融合处理的延时。在车端部分,智能网联汽车通过其搭载的高精度自定位设备可以获得自定位观测数据,但其中算法处理部分的内容较少,因此不考虑其处理时延。通过V2I(vehicle-to-infrastructure)传输的智能网联汽车自定位数据会存在时延,针对时延建模

并根据其产生因素划分为同步时延和传输时延。通过对于这两种不同时延产生的方式进行了时延模型搭建,并提出一种时延同步方法。在路侧部分,路侧架设的激光雷达设备在完成与车道级地图标定后,通过激光雷达识别通过该区域的车辆信息,提供通过该区域的车辆的初始位置信息。其中不同传感器时间戳对齐的基准为路侧边缘计算单元的时间戳,所采用的为路侧算法处理后的时间戳,因此对于路侧部分的算法处理时延包含在时间戳内,所关注点在车路协同中异构传感器之间的同步时延与传播时延。

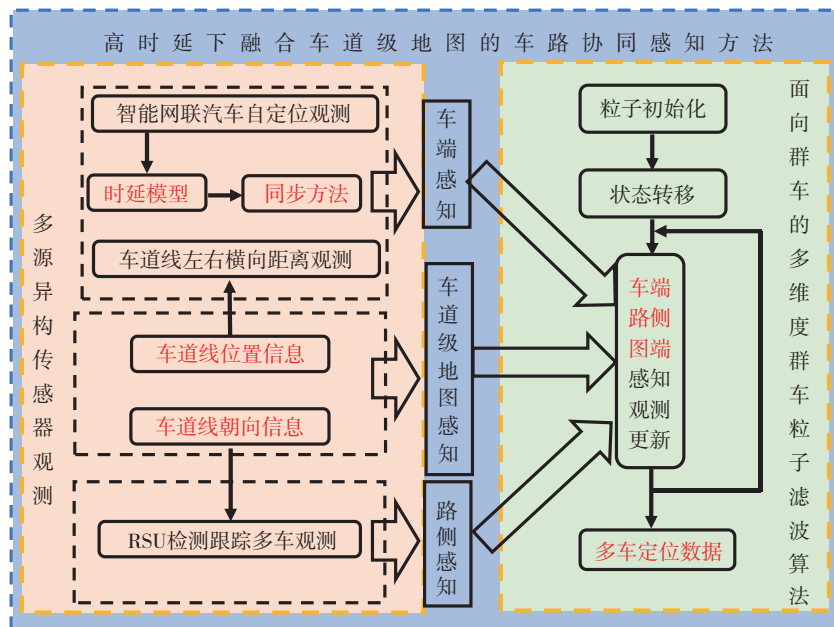


图1 算法流程图

所提出的多维度群车粒子滤波算法中将群车的历史轨迹信息放入状态变量中,基于此获得车辆的朝向信息。在更新中首先融合路侧跟踪检测的车辆位置信息和车道级地图中车道线朝向信息;其中表示智能网联汽车的状态变量融合时延同步处理后的智能车自定位信息和左右车道线横向观测及车道线方程位置信息,车端发送至边缘计算单元的数据包括智能网联汽车自定位结果和左右车道线横向约束。考虑车辆在结构化道路上行驶,正常情况下车道线横向距离在时延中变化较少,因此只考虑对自定位结果进行时延同步处理,如此便完成了全部更新的过程。本文使用的是OpenDrive1.8标准的车道级地图。构建的路侧设备及该区域的群车行驶场景示意图如图2所示,一般车路协同系统多设备通讯

如图3所示。




图2 群车行驶场景

### 1.1 基于时延同步的车端观测

系统中车端部分观测为智能网联车辆自定位结果和左右车道线横向距离信息,通过V2I通讯发送至边缘计算单元,如图4所示。其中自定位结果由车载高精度自定位装置提供,左右车道线横向距离




图3 一般车路协同系统多设备通讯示意图



图4 智能网联汽车传感器搭载示意图

信息由车辆前视图像传感器所提供。由于网络通讯、环境噪声等因素的干扰,系统的实时性不能保证,即所发送的数据可能会存在随机延时。智能网联车辆与边缘计算单元通过V2X进行通讯因此存在时延问题,而路侧RSU设备一般与边缘计算单元进行有线连接暂不考虑时延问题。对于所存在的随机时延进行分析可得,车路协同系统中的延时主要分为同步时延和传输时延两个部分。其中同步时延是指不同传感器的时钟频率并不严格的一一对应而产生的同步时延误差,而传输时延是指数据在通讯过程产生的延时误差,它们一起构成了车路协同通讯中时延部分。其中智能网联车辆的自定位观测信息有自身搭载的高精度定位装置提供,左右车道线横向距离信息由搭载智能网联汽车的视觉传感器提供。

### 1.1.1 针对同步时延误差模型构建及同步方法

不同传感器的时钟基准通常由传感器内的晶体振荡器提供。由于不同的晶体振荡器在制造过程中具有微小差异,同时不同传感器在工作时它的频率不一样,所以会导致不同传感器的时间戳并不一致<sup>[19]</sup>。当前车路协同系统中不同传感器通过联网对齐后,还会存在两个异构传感器时间戳不一致的情况。如图5所示,两个传感器拥有两个不同的时间戳 $s$ 和 $t$ ,经过联网对齐后,存在不严格一致的情况,若以传感器2为基准,则传感器1就存在 $\varepsilon$ 的同步时间误差。基于此本文提出以正态分布搭建 $\varepsilon$ 的延迟同步误差模型,如图6所示。




图5 随机时延误差分析




图6 时延模型构建

在本文的同步方法中以边缘计算单元的时间频率为基准,所有传感器向其对齐。车端通讯数据发送到边缘计算单元,以边缘计算单元的时间戳为基准进行同步。而车端发送的通讯字段包含了发送时刻的时间戳、自定位坐标、左右车道线距离和速度矢量信息。基于此,提出如下同步方法,以边缘计算单元的时间戳为基准,向它对齐。用所获取的发送时间戳与对齐时间戳做差得 $\varepsilon_k$ ,并乘以速度矢量信息 $v_k$ ,得到延迟同步补偿 $e_k$ 后与位置坐标 $X_{ego}$ 求和得到以边缘计算单元时间戳的移动信息,如式(1)所示:

$$X_{MEC} = e_k + X_{ego} = \varepsilon_k \times v_k + X_{ego} \quad (1)$$

即完成了对于边缘计算单元的时间对齐。

### 1.1.2 针对通讯时延误差模型构建及同步方法

在完成不同传感器之间的时间戳对齐后,本文再考虑数据通讯时延问题。受网络通讯、环境噪声等因素的干扰,系统的实时性并不能准确保证,即发送的动态数据可能会受到随机时延的影响。而通讯延时 $\tau$ 主要为传输时延 $\tau_t$ ,传输时延是指数据从发送节点出发,在无线通讯信道中传播到接收节点所需要的时间。

如图6所示,其中时间戳1中实心黑色的点是车端发送的智能网联汽车自定位车辆数据时刻,时间戳2中实心灰色的点是边缘计算单元实际接收的时刻,而空心的点表示如果没有延迟应该达到的时间点。因为传输具有不确定性,所以每个数据的传输延时并不相同。采用瑞利分布模拟时延传输模型<sup>[8]</sup>,图6详尽地展示了车端通过V2I通讯传输至边缘计算单元的时延过程,基于上述过程,本文提出了针对V2I通讯传输时延同步的处理方法。

已知在 $t'_{k-2}$ 时刻收到 $t_{k-2}$ 时刻车辆的位置 $V_{k-2}$ ,在 $t'_{k-1}$ 时刻收到 $t_{k-1}$ 时刻车辆的位置 $V_{k-1}$ ,现在时刻是 $t_k$ 。需要获得 $t_k$ 时刻车辆的位置,设为 $V_k$ 。基于匀速运动模型, $V_{k-2}$ 、 $V_{k-1}$ 、 $V_k$ 之间的关系如下所示:

$$V_{k-1} = \frac{t_k - t'_{k-1}}{t_k - t_{k-2}} V_{k-2} + \frac{t'_{k-1} - t_{k-2}}{t_k - t_{k-2}} V_k \quad (2)$$

已知的 $V_{k-2}$ 和 $V_{k-1}$ ,基于匀速运动模型,本文可以推理出 $V_k$ 的值。将推理出的 $V_k$ 值,当作 $t_k$ 时刻的值,作为传输的时延同步。

而车端所获得的左右车道线横向距离观测信息,由于智能车辆在行驶过程中与车道线之间的距离变化幅度不大,因此可以短暂地忽略时延的影响。

### 1.2 路侧观测信息

系统中路侧部分观测为路侧携带的激光雷达设备对局部区域车辆位置观测生成的数据。利用高精

度地图中的点、线等先验特征信息,提升车辆检测的效率,提高车辆跟踪的精度。首先,通过多激光雷达的标定结果,利用车道级地图道路边缘线特征投影完成三维点云区域中感兴趣区域(ROI)提取,从而有效减少了待处理点云的数量,提升计算效率;然后,利用基于极化图<sup>[20]</sup>高斯混合背景模型(P-GMM)的背景建模方法构建场景背景,通过背景差分法完成ROI区域内目标快速检测,根据标定结果对多激光雷达检测目标进行拼接,利用极化图完成运动目标快速检测,避免了大规模激光点云的直接处理,有效提升检测效率;最后,利用车辆航向与车道线方向一致性约束,将车道级地图中的车道方向转化为卡尔曼滤波框架下的车辆状态线性约束,改善了车辆检测与轨迹跟踪的性能。通过路侧激光雷达与车道级地图之间的外参标定信息,即可将获得的多车检测结果坐标转化为车道级地图坐标 $(x_U, y_U)$ ,完成了路侧部分的观测。

### 1.3 车道级地图观测

在本文算法中将车道级地图作为一种特殊的传感器信息,输出其车道线朝向观测和车道线位置观测,如图7和图8所示。




图7 车道线航向角信息




图8 车道线横向约束信息

在一般情况下,车辆行驶会遵循车道线的方向,因此,通过车道级地图中保存的车道线朝向 $\theta_m$ ,可以建立车辆航向角之间的关系:

$$\theta_1 = \theta_m \quad (3)$$

在实际计算过程中可以用车辆运行前后帧求出车辆运行航向角:

$$\tan \theta_1 = \frac{x_i^y - x_{i-1}^y}{x_i^x - x_{i-1}^x} \quad (4)$$

根据式(3)可以求出 $\theta_1$ ,因此可以建立式(4)所示车道线朝向约束信息。

如图4所示,智能网联汽车可以通过自身搭载的传感器获得车辆与左右车道线的距离信息 $d_1$ 。而直线方程由车道级地图提供,其形式为

$$[\sin \theta_m \quad -\cos \theta_m \quad d_m][x \quad y \quad 1]^T = 0 \quad (5)$$

式中: $\theta_m$ 、 $d_m$ 为直线方程参数; $x$ 、 $y$ 为平面中的坐标点。依据式(4)可以推算出

$$d_m^{(x,y)} = [\sin \theta_m \quad -\cos \theta_m \quad d_m][x \quad y \quad 1]^T \quad (6)$$

式中 $d_m^{(x,y)}$ 表示坐标 $x$ 、 $y$ 下车道级地图提供的车道线距离观测信息。

在理想情况下,假定:

$$d_m^{(x,y)} = d_1 \quad (7)$$

因此可以依据式(6)建立车道线位置约束信息。

#### 1.4 面向群车协同的多维度群车粒子滤波框架

在大数据融合的应用场景中,粒子滤波是应用最广泛的算法之一,特别是在非线性场景的优越性能适用于多源异构数据的融合。基于此,本文提出了一种面向群车协同的多维度群车粒子滤波框架,将粒子的状态变量表示群车的状态,这种表示方式可以将多个车辆的信息一起优化。该框架在获得路侧搭载的激光雷达最初几帧观测的基础上完成粒子的初始化,然后使用基于历史轨迹预测方法进行状态转移,在粒子的更新部分首先使用路侧激光雷达检测跟踪出的车辆位置数据融合车道级地图的车道线朝向信息做融合处理。针对智能网联汽车传输的车端自定位信息,使用1.1节所提到的同步算法进行相关时延同步后车端的自定位结果和智能车与车道线的左右横向观测信息融合车道级地图车道线位置信息,更新粒子的权重完成粒子更新。算法流程图如图9所示。

所提出的面向群车协同的多维粒子滤波框架的更新部分中将路侧RSU观测和车道级地图车道线朝向信息融合对车辆定位的后验概率进行修正,提升车辆的定位精度。后验概率分布由历史轨迹先验

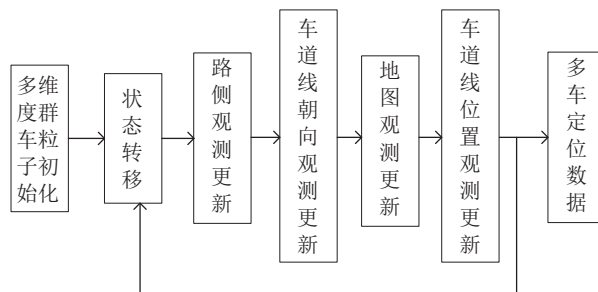


图9 面向群车的多维度群车粒子滤波算法流程图

分布 $X_{t-1}$ 、路侧RSU观测 $Y_t^U$ 和车道级地图车道线朝向 $Y_t^O$ 这3部分组成。在完成路侧观测和车道级地图车道线朝向观测融合的粒子权重更新后,针对智能网联汽车,融合智能网联汽车的自定位信息和车道线横向约束观测值进一步提升智能网联汽车的定位精度,其额外添加的后验概率为时延同步智能车自定位信息 $Y_t^V$ 、车道级地图车道线观测 $Y_t^d$ 。

原始粒子滤波分为预测阶段、更新阶段和重采样阶段,所提出多维粒子滤波框架主要在预测阶段和更新阶段以及粒子的状态变量部分对原始粒子滤波进行改进。在预测阶段,使用历史轨迹数据预测模型来预测当前粒子分布,这种历史轨迹状态转移模型,以轨迹信息表征的粒子状态可以很好地应用于所构建的车路协同智能网联系统中时延同步方法;在路侧观测融合车道级地图车道线朝向观测更新阶段,将路侧观测和车道级地图的车道线朝向信息作为输入对粒子权重进行更新。而在车端观测融合车道级地图车道线位置信息更新阶段,会额外将经过延迟同步处理后的智能网联汽车自定位结果、智能车对车道线左右横线观测约束做为输入,对粒子权重进行更新;而在重采样阶段,根据粒子的权重值对粒子进行筛选,淘汰权重低的粒子,保留权重高的粒子。多次重复上述过程,最终粒子会聚集在真值附近,从而获得更加精确真实的群车信息。

##### 1.4.1 多维度群车粒子滤波中的状态定义和初始化

本文采用路侧激光雷达最初的观测信息获得群车初始化的位置坐标。在贝叶斯框架中求最大后验估计的表达式为

$$X_t^* = \arg \max_{X_t} P(X_t | X_{0:t-1}, Y_{0:t}) \quad (8)$$

式中: $X_t$ 表示第 $t$ 时刻群车的状态变量; $Y_t$ 表示第 $t$ 时刻各个不同传感器的观测信息。

设定状态变量  $X_t$  如式(9)所示,其中  $t$  表示时刻信息。在  $X_t$  表示的车群中车辆上一时刻的历史位置,所以不需要额外的速度或加速度信息,可以更好地应用于所提出的延迟同步算法。 $x_t^k, y_t^k$  分别表示第  $t$  时刻观测中第  $k$  辆车的位置信息即为车道级地图坐标系下的横坐标和纵坐标。

$$X_t = \begin{bmatrix} x_{t-1}^1 & y_{t-1}^1 \\ x_t^1 & y_t^1 \\ x_{t-1}^2 & y_{t-1}^2 \\ x_t^2 & y_t^2 \\ \vdots & \vdots \\ x_{t-1}^k & y_{t-1}^k \\ x_t^k & y_t^k \end{bmatrix} \quad (9)$$

其状态转移方程为

$$X_t = \begin{bmatrix} 0 & 1 & 0 & 0 & \cdots & 0 & 0 \\ -1 & 2 & 0 & 0 & \cdots & 0 & 0 \\ 0 & 0 & 0 & 1 & \cdots & 0 & 0 \\ 0 & 0 & -1 & 2 & \cdots & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & 0 & 0 & \cdots & 0 & 1 \\ 0 & 0 & 0 & 0 & \cdots & -1 & 2 \end{bmatrix} X_{t-1} + BU_t \quad (10)$$

直接利用后验分布得到粒子的抽样分布较为困难,基于上述状态转移模型,选取重要性密度函数为

$$\pi(X_t | X_{0:t-1}, Y_{0:t}) = P(X_t | X_{t-1}, Y_t) = \frac{P(Y_t | X_t)P(X_t | X_{t-1})}{\int (Y_t | X_t)P(X_t | X_{t-1})dX_t} \quad (11)$$

考虑到第  $t$  时刻的观测只与第  $t-1$  时刻的观测有关,则将式(11)化为

$$\pi(X_t | X_{0:t-1}, Y_{1:t}) = P(X_t | X_{t-1}) \quad (12)$$

式中  $Y_t$  为表示  $t$  时刻的所有观测信息。

#### 1.4.2 粒子权重更新

通过重要性密度函数采样得到粒子集后,需要对粒子权重进行更新。根据式(12)得到粒子的权重更新迭代式为

$$\hat{\omega}_t^{(i)} = \omega_{t-1}^{(i)} \frac{P(Y_t | X_t^{(i)})P(X_t^{(i)} | X_{t-1}^{(i)})}{\pi(X_t | X_{0:t-1}, Y_{0:t})} = \omega_{t-1}^{(i)} P(Y_t | X_t^{(i)}) \quad (13)$$

式中  $P(Y_t | X_t^{(i)})$  是观测变量  $Y_t$  在粒子  $X_t^{(i)}$  下的似然模型。在本文所提出的粒子滤波框架中,观测变量  $Y_t$  主要分为路侧观测  $Y_k^R$  和车道级地图车道线朝向观测  $Y_k^\theta$ ,车端自定位观测  $Y_k^V$  和车道级地图车道线位置观测  $Y_k^d$ 。为了使所提出的粒子权重更新公式推导过程易于阅读,将其按来源分为路侧  $U_t^R$ 、车端  $V_t$  和

地图  $M$  3个部分。其中地图  $M$  观测有两种分别是车道线朝向观测  $M_{\theta_m}$  和车道线位置观测  $M_{d_m}$ 。以上观测均满足条件独立性假设,因此似然模型  $P(Y_t | X_t^{(i)})$  可以写成:

$$P(Y_t | X_t^{(i)}) = P(U_t^R, V_t, M | X_t^{(i)}) = P(U_t^R | X_t^{(i)})P(V_t | X_t^{(i)})P(M | X_t^{(i)}) \quad (14)$$

粒子的权重分配由如下3部分组成。

(1)由路侧观测更新部分

$$P(U_t^R | X_t^{(i)}) = P(U_t^R | S_{U_t^R} X_t^{(i)}, X_t^{(i)} - S_{U_t^R} X_t^{(i)}) \quad (15)$$

式中  $S_{U_t^R}$  为针对路侧观测部分的投影矩阵。因为  $X_t^{(i)}$  的状态变量中每一行都表示群车中不同车辆的轨迹信息且它们之间相互独立,所以用投影矩阵  $S_{U_t^R}$  来筛选出群车中路侧观测相关的对象进行观测更新,因此  $S_{U_t^R} X_t^{(i)}$  表示群车中路侧观测的对象,  $X_t^{(i)} - S_{U_t^R} X_t^{(i)}$  表示群车中非路侧观测的对象。 $S_{U_t^R} X_t^{(i)}$ 、 $X_t^{(i)} - S_{U_t^R} X_t^{(i)}$  是条件独立的,所以本文可以将式(15)写成:

$$P(U_t^R | S_{U_t^R} X_t^{(i)}, X_t^{(i)} - S_{U_t^R} X_t^{(i)}) = P(U_t^R | S_{U_t^R} X_t^{(i)}) = \frac{1}{2\pi |\Sigma_{U_t^R}|^{1/2}} \exp\left(-\frac{1}{2} [S_{U_t^R} X_t^{(i)} - U_t^R]^T \Sigma_{U_t^R}^{-1} [S_{U_t^R} X_t^{(i)} - U_t^R]\right) \quad (16)$$

式中  $\Sigma_{U_t^R}$  为路侧观测的协方差。

(2)车端观测更新部分

$$P(V_t | S_V X_t^{(i)}, X_t^{(i)} - S_V X_t^{(i)}) = P(V_t | S_V X_t^{(i)}) = \frac{1}{2\pi |\Sigma_V|^{1/2}} \exp\left(-\frac{1}{2} [S_V X_t^{(i)} - V_t]^T \Sigma_V^{-1} [S_V X_t^{(i)} - V_t]\right) \quad (17)$$

同理在式(17)中,  $S_V$  为车端观测部分投影矩阵,用来对  $X_t^{(i)}$  中表示车端观测部分的更新,  $\Sigma_V$  表示车端观测量的协方差。

(3)车道级地图观测更新部分

$$P(M | X_t^{(i)}) = P(M_{\theta_m}, M_{d_m} | X_t^{(i)}) = P(M_{\theta_m} | X_t^{(i)})P(M_{d_m} | X_t^{(i)}) \quad (18)$$

其中,地图  $M$  观测由两部分组成,分别为车道线朝向观测  $M_{\theta_m}$  和车道线位置观测  $M_{d_m}$ 。其中:

$$P(M_{\theta_m} | X_t^{(i)}) = \frac{1}{2\pi |\Sigma_{\theta_m}|^{1/2}} \exp\left(-\frac{1}{2} [\theta_m(S_{\theta_m} X_t^{(i)}) - \Theta_1]^T \Sigma_{\theta_m}^{-1} [\theta_m(S_{\theta_m} X_t^{(i)}) - \Theta_1]\right) \quad (19)$$

式中:  $M_{\theta_m}$  为车道级地图提供车道线朝向观测;  $\theta_m(S_{\theta_m} X_t^{(i)})$  为  $X_t^{(i)}$  中车辆前后时刻历史轨迹的推算,具体推算方法见式(3);  $\Theta_1$  为以  $\theta_1$  建立的车道线朝向矩阵,并以式(2)建立约束关系。

$$P(\mathbf{M}_{d_m} | \mathbf{X}_t^{(i)}) = \frac{1}{2\pi |\Sigma_{d_m}|^{1/2}} \exp\left(-\frac{1}{2} [\mathbf{d}_m(\mathbf{S}_{d_m} \mathbf{X}_t^{(i)}) - \Gamma_1]^T \Sigma_{d_m}^{-1} [\mathbf{d}_m(\mathbf{S}_{d_m} \mathbf{X}_t^{(i)}) - \Gamma_1]\right) \quad (20)$$

式中:  $\mathbf{M}_{d_m}$  为车道级地图提供车道线位置观测;  $\mathbf{d}_m(\mathbf{S}_{d_m} \mathbf{X}_t^{(i)})$  函数依据智能车车辆状态与车道级地图车道方程求出横向距离, 具体推算方法见式(5);  $\Gamma_1$  表示以  $d_1$  建立的车道线距离观测信息矩阵, 并以式(6)建立约束关系。

至此使用式(13)对每一个粒子的权重进行更新, 粒子权重更新后的权重用  $\hat{\omega}_t^{(i)}$  表示, 最后归一化后的粒子权重为

$$\omega_t^{(i)} = \frac{\hat{\omega}_t^{(i)}}{\sum_i \hat{\omega}_t^{(i)}} \quad (21)$$

通过所提粒子滤波框架将多源异构传感器的不同观测信息以概率密度的形式结合, 在边缘计算单元中提升群车定位精度信息。

#### 1.4.3 重采样

对于每一个粒子, 粒子的权重大小代表了粒子的可信度, 一般而言, 需要权重大的粒子对于滤波的作用越大, 所以通过蒙特卡洛采样方法选择性地保留权重大的粒子, 舍弃权重小的粒子。但随着迭代次数的增加, 大部分的粒子权重都会向零接近, 小部分的粒子获得了大的权重, 这个现象称之为粒子退化现象。为了避免粒子退化导致的粒子滤波性能下降, 再经过若干次迭代后, 需要对粒子进行重分布。重分布可以增加粒子的多样性, 采用有效采样数来判断粒子是否产生了退化。

$$N_{\text{eff}} = \frac{1}{\sum_{i=1}^n (\omega_i^{(i)})^2} \quad (22)$$

当  $N_{\text{eff}}$  小于  $n/2$  时, 就需要对粒子滤波进行重采样, 其中  $n$  为粒子的总数。

## 2 实验结果与分析

为了验证本文所提出的算法的有效性, 考虑到实验场景的复杂性, 利用开源自动驾驶模拟器 Carla, 搭建车路协同实验场景, 进行仿真实验, 流程如图10所示。Carla是一款由Intel、巴塞罗那计算视觉研究中心联合研制的基于UE4引擎的开源世界仿真平台。Carla中的地图符合OpenDrive1.8标准, 可以为基于地图的车道线横向约束提供车道级地图方面支持。




图10 实验测试流程

其中路侧激光雷达相关参数设置如表1所示, 为了评估本文方法的效果, 将车路协同感知方法的精度转化为车辆的定位误差, 将其定义如下:

$$RMES = \sqrt{\frac{\sum_{k=0}^{N-1} \|\mathbf{x}_k^{\text{gt}} - \mathbf{x}_k^{\text{r}}\|_2^2}{N}} \quad (23)$$

式中:  $N$  为当前累计定位次数;  $\mathbf{x}_k^{\text{gt}}$  为  $k$  时刻车辆的定位真值;  $\mathbf{x}_k^{\text{r}}$  为  $k$  时刻车辆的定位结果。

表1 路侧激光雷达设置

参数	设置
扫描线数	128线
扫描半径	200 m
水平扫描角度	360°
垂直扫描角度	-30°~10°

为直观评估本文方法降低定位误差的性能, 定义性能提升率如下:

$$\lambda = \left(1 - \frac{RMSE_A}{RMSE_B}\right) \times 100\% \quad (24)$$

式中:  $RMSE_A$  为本文算法的误差;  $RMSE_B$  为其它方法定位误差。  $\lambda$  越大则说明本文算法比其它算法性能更好, 反之则效果不佳。

本文分别在仿真场景中模拟搭建低时延场景和高时延场景进行实验, 且均在相同的计算机环境下进行测试, 其配置为: CPU, Intel Core i9-13900KF 5.8 GHz; 内存, 64 GB; 显卡, GeForce RTX 4090 SUPRIM X 24 G。开发环境为 Visual Studio 2021 C/C++。

### 2.1 低时延场景下测试结果与分析

低时延场景中, 车流量与建筑物较少, 通信基站数量较少, 通讯的干扰并不严重, 基于此搭建如图11所示的实验测试场景, 路侧设备搭建如图12所示。局部动态地图的范围为A点到B点的一段区域。记录车辆从A处行驶至B处的轨迹真值作为算法性能验证的数据来源。



图 11 低时延场景下实验测试场景及车辆轨迹生成路径



图 12 路侧设备搭建示意图

### 2.1.1 时延同步算法测试与验证

为了保证实验条件的一致性和可复现性,将Carla仿真服务端与同步方法部署在同一服务器中,通过人工叠加伪随机时延的方式模拟V2X传输延对系统的干扰。数据发送频率设定为10 Hz,即车端与边缘计算单元的时间戳间隔设定为100 ms。

### 2.1.2 时延数据构建

参照文献[8]中对于车路协同真实时延统计数据的实验结果,其中在不同速度下车路协同通讯中传播时延的模型参数并没有太大变化,而本文主要考虑传播与同步时延的影响,暂未对不同的速度进行实验分析。

首先将车端时间戳向边缘计算单元对齐,用高斯分布模拟两个不同传感器的时间戳的不一致。将车端与边缘计算单元的时间戳间隔设定为100 ms,但它们并不是一一对齐的,选取车端时间戳最接近边缘计算单元时间戳为车端被同步时间戳。以边缘计算单元的时间戳 $t_k$ 为均值, $\sigma$ 取10 ms为标准差选取正态分布模型,其pdf(probability density function)如式(25)所示。

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-t_k)^2}{2\sigma^2}} \quad (25)$$

在车端时间戳往边缘计算单元时间戳同步完成后,针对车端与边缘计算单元的通讯时延问题,采用文献[8]中的实验结果,利用瑞利分布进行时延模拟。已发送时刻为均值,以发送时间间隔的一半50 ms为边界搭建瑞利分布模型,其pdf如式(26)所示。其

数据通讯延时如图13所示,其中蓝色的线为数据发送时间间隔100 ms,而红色的线为数据延时时间,绿色的线为数据接收的时间间隔,平均延时12.77 ms。

$$f(x; \sigma) = \frac{x}{\sigma^2} e^{-\frac{x^2}{2\sigma^2}} \quad (26)$$




图 13 低时延场景数据通讯延时

### 2.1.3 测试验证

经过本文所提出的同步算法的计算,推算出了 $t_k$ 时刻的车辆的 $x$ 与 $y$ 坐标,为了更好地展示本文同步方法的优越性,将 $x$ 和 $y$ 分别由图14(a)和图14(b)表示。

### 2.1.4 同步算法对比

本节采用文献[7]中所提出针对延迟的同步方法(方法1)与本文所提出的同步方法(方法2)开展实验,对比本文方法的优越性。方法1将接收到的车辆位置数据同步到发送时刻后对在当前时刻的进行融合更新,且在再次接收到观测值之前,一直以原始状态转移进行轨迹更新。而本文所提出的方法2是对延迟模型进行区分并针对不同的延迟模型进行同步方法,推算当前时刻的车辆位置数据。

为了保证测试结果的可重复性,本节选取与2.1.3测试验证小节相同的车辆轨迹,在低时延场景中,智能网联汽车自定位精度在厘米级,基于此设定智能网联汽车车端发送的自定位误差服从0.25的正态分布误差。其中经过两种同步算法生成后的轨迹对比如图15所示,方法1相对于所提出的方法2车辆的定位轨迹偏移明显。它们的RMES值如图16所示,其中本文所提出的方法的均方根误差最后稳定在0.60 m,而方法1的均方根误差稳定在1.15 m,相比提升了47.8%。实验结果如表2所示,所提方法较文献[7]中的同步方法,提升效果明显。







图 14 低时延场景同步算法后  $x$  与  $y$  坐标

图 15 低时延场景同步算法轨迹对比

2.1.5 多维粒子滤波输出的定位结果测试与验证  
对所提出的多维粒子滤波框架进行性能验证。图 11 所示地图对应的车道级地图如图 17 所示。

利用图 10 所示测试流程,对所提算法输出轨迹进行分析。实验轨迹如图 18 所示,其中对比算法使用文献[7]中使用的卡尔曼滤波融合来融合时延同步后车端的自定位数据和路侧观测数据。为验证所提出的随机时延下融合车道级地图的多维度群车粒子滤波方法性能上的优越性,比较仅 RSU 路侧部分定位结果误差、融合车道线朝向信息后输出的误差和车道级地图车道线位置信息的定位误差(本文算法)。




图 16 低时延场景同步算法对比 RMES 误差图

RMES 误差对比如图 19 所示,性能对比如表 3 所示,其中仅 RSU 路侧部分定位误差稳定在 0.65 m 左右,对比算法的定位误差稳定在 0.57 m 左右,而本文所提多维度群车粒子滤波算法中融合车道线转向信息输出定位误差稳定在 0.42 m 左右,本文算法

表 2 不同同步方法效果对比

方法	RMES/m	$\lambda$ /%
方法 1	1.15	47.8
方法 2(本文方法)	0.60	




图 17 对应车道级地图




图 18 低时延场景轨迹对比图




图 19 低时延场景定位 RMSE 误差图

的定位误差稳定在 0.29 m。定位误差累积分布函数图如图 20 所示,所提出的方法定位累计误差分布中小于 0.36 m 的部分占比达到 90%,小于 0.5 m 的占比达到 90%。RSU+车道线朝向方法在累计误差分布中小于 0.5 m 的部分占比达到 80%,小于 0.66 m 的占比达到 90%。而对比算法中,小于 0.60 m 的占比达到 80%,小于 0.7 m 的占比达到 90%。对比其它方法可以看出所提出方法融合了车道级地图和未

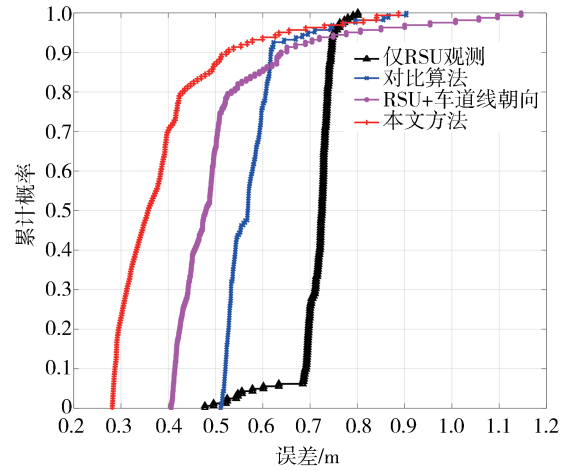


图 20 低时延场景定位误差累积分布函数图

融合地图在定位精度的提升上具有显著优势。对比算法是因为融合的车端定位经过所对比的同步算法同步后的误差比本文所提同步算法的误差大,所以高精度的车端自定位并没有给融合算法提升。而本文算法的车端定位同步后精度丢失不多,且有车道级地图,所以输出的定位精度较高。

表 3 不同定位方法性能对比

定位方式	RMSE/m	$\lambda/\%$
仅 RSU	0.69	57.9
对比算法	0.57	49.1
RSU+车道线朝向信息	0.42	31.0
本文算法	0.29	

### 2.2 高时延场景下测试结果与分析

在高时延场景中建筑物和车流量很多,相关的通信基站数量较多,会产生严重的城市峡谷效应,通讯延迟相对于低时延场景而言更加严重,并且智能网联汽车的自定位精度误差也会加大很多。基于此搭建如图 21 所示高时延测试场景,路侧设备搭建如图 22 所示。局部动态地图的范围为 A 点到 B 点到 C 点到 D 点到 E 点的一段区域,并在 D 处设置进行一次换道行驶。记录车辆依次从 A 处行驶至 B、C、D、E 处的轨迹真值作为算法性能验证对比的数据来源。

#### 2.2.1 时延数据构建

相关初始设定与低时延场景测试场景一致,在时间戳对齐环节选取以式(25)pdf为数据生成模型,其中以边缘计算单元的时间戳  $t_k$  为均值,  $\sigma$  取 20 ms 为标准差。在通讯时延同步环节设定以发送时间间隔 100 ms 为边界搭建瑞利分布模型,其pdf为式(26)。

其数据通讯延时如图 23 所示,其中蓝色的线为




图 21 高时延场景下实验测试场景及车辆轨迹生成路径



图 22 路侧设备搭建示意图

数据发送时间间隔 100 ms, 而红色的线为数据延时时间, 绿色的线为数据接收的时间间隔, 平均延时 25.20 ms。





图 23 高时延场景数据通讯延时


### 2.2.2 测试验证

为了更好地凸显本文所提出的同步方法, 如图 24 所示, 将车辆的坐标  $x$  和  $y$  分别由图 24(a) 和图 24(b) 来表示。由图 24 可以看出, 本文所提出的同步

方法同步时延后接收的车辆的  $x$  坐标十分接近真值, 特别是在车辆变换车道后也快速地同步至真值附近, 同步效果良好。



(a) 同步算法后  $x$  坐标




(b) 同步算法后  $y$  坐标


图 24 高时延场景同步算法后  $x$  与  $y$  坐标

### 2.2.3 同步算法对比

为了保证测试结果的可重复性, 本节选取了与 2.2.2 测试验证小节相同的车辆轨迹, 在高时延场景中智能网联汽车的自定位精度受城市中建筑物、通信基站等的干扰, 基于此设定智能网联汽车车端发送的自定位误差服从 0.50 的正太分布误差。其中经过两种同步算法生成后的轨迹对比如图 25 所示, 方法 1 相对于所提出的方法 2 车辆的定位轨迹偏移明显。它们的 RMES 值如图 26 所示, 其中本文所提出的方法的均方根误差最后稳定在 1.40 m, 而方法 1 的均方根误差稳定在 1.90 m, 相比提升了 26.3%。实验结果表明, 所提方法较文献[7]中的同步方法, 提升效果明显。最终实验数据对比如表 4 所示。



(a) 同步算法后x坐标



(b) 同步算法后y坐标

图 25 高时延场景同步算法后 x 与 y 坐标

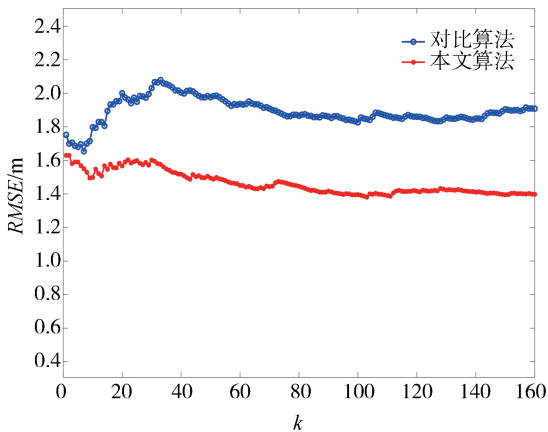


图 26 高时延场景同步算法对比 RMSE 误差图

表 4 不同同步方法效果对比

方法	RMSE/m	$\lambda$ /%
方法 1	1.90	26.3
方法 2(本文方法)	1.40	

### 2.2.4 多维粒子滤波输出的定位结果测试与验证

对所提出的多维度群车粒子滤波框架进行性能验证。图 21 所示地图对应的车道级地图如图 27 所示。




图 27 对应车道级地图

利用图 10 所示测试流程,对于多维度群车粒子滤波输出轨迹进行分析。为验证所提出的随机时延下融合车道级地图的多维粒子滤波性能上的优越性,比较仅 RSU 观测结果误差、融合车道级地图车道线朝向信息后的输出误差和融合智能车车端信息与车道级地图车道线位置信息(本文算法)的定位误差。

轨迹如图 28 所示,车辆在 D 处(见图 21)进行了一次换道,在换道时所提出的算法无法融合车道级地图的信息,所以出现了定位误差变大,当换道结束后,算法融合车道级地图信息,所以其定位精度提升明显。如图 29 所示,单 RSU 定位误差稳定在 1.09 m 左右,而所提融合车道线朝向信息输出定位误差稳定在 0.56 m 左右,而融合车端自定位和车道线位置信息输出定位误差稳定在 0.49 m。如图 30 所示,所




图 28 高时延场景轨迹对比图




图 29 高时延场景定位 RMSE 误差图




图 30 高时延场景定位误差累计分布函数图

提出的方法定位累计误差分布中小于 0.48 m 的部分占比达到 80%, 小于 0.52 m 占比达到 99%。相较于其它方法, 本文算法精度提升明显。最终实验数据对比如表 5 所示。

表 5 不同定位方法性能对比

定位方式	RMSE/m	$\lambda/\%$
仅RSU	1.09	55.0
对比算法	0.95	48.4
RSU+车道线朝向信息	0.56	12.5
本文算法	0.49	

### 3 结论

本文提出了一种高时延下融合车道级地图的多车协同感知定位方法。该方法首先对车路协同中普遍存在的延迟问题进行建模分析并提出同步方法,

在同步完成后, 提出一种多维度群车粒子滤波框架, 将粒子的状态表示为多车的轨迹信息, 建立了以车辆的历史轨迹进行粒子状态转移模型, 这种转移方式可以很好地应用于所提出的处理时延同步的方法, 减小在数据传输过程中因为数据抖动、数据拥挤而产生的时延对系统实时性的影响。实验结果表明, 所提出的同步方法能有效提升车路协同智能网联中数据传输的实时性与流畅性, 所提出的多维度群车粒子滤波算法能有效地融合多种观测信息提升边缘计算单元的群车定位精度, 进而提升多车定位数据生成的孪生地图的精度和稳定性。

### 参考文献

[1] 胡钊政, 孙勋培, 张佳楠, 等. 基于时空图模型的车-路-图协同定位方法[J]. 吉林大学学报(工学版), 2024, 54(5): 1246-1257.  
 HU Z Z, SUN X P, ZHANG J N, et al. Vehicle-road-map collaborative location method based on spatiotemporal graph model [J]. Journal of Jilin University (Engineering and Technology Edition), 2024, 54(5): 1246-1257.

[2] 伍毅平, 李海舰, 赵晓华, 等. 车路协同雾天预警系统对车辆运行生态特性的影响[J]. 交通运输工程学报, 2021, 21(4): 259-268.  
 WU Y P, LI H J, ZHAO X H, et al. Effect of fog weather warning system under cooperative vehicle infrastructure on vehicle operating eco-characteristics [J]. Journal of Traffic and Transportation Engineering, 2021, 21(4): 259-268.

[3] 郑莹莹, 周俊龙, 申钰凡, 等. 时间和能量敏感的端-边-云车路协同系统资源调度优化方法[J]. 计算机研究与发展, 2023, 60(5): 1037-1052.  
 ZHENG Y Y, ZHOU J L, SHEN Y F, et al. Time and energy-sensitive end-edge-cloud resource provisioning optimization method for collaborative vehicle-road systems [J]. Journal of Computer Research and Development, 2023, 60(5): 1037-1052.

[4] 高志军, 王江锋, 陈磊, 等. 基于动态距离窗的交叉口 CAV 轨迹规划算法[J]. 汽车工程, 2021, 43(4): 537-545.  
 GAO Z J, WANG J F, CHEN L, et al. Trajectory planning algorithm for cav at intersections based on dynamic distance windows [J]. Automotive Engineering, 2021, 43(4): 537-545.

[5] MOAYEDI M, FOO Y K, SOH Y C. Adaptive Kalman filtering in networked systems with random sensor delays, multiple packet dropouts and missing measurements [J]. IEEE Transactions on Signal Processing, 2010, 58(3): 1577-1588, 2010.

[6] MA J, SUN S L. Optimal linear estimators for systems with random sensor delays, multiple packet dropouts and uncertain observations [J]. IEEE Transactions on Signal Processing, 2011, 59(11): 5181-5192.

[7] 邱威智, 上官伟, 柴琳果, 等. 面向车路协同孪生仿真测试的多尺度滤波同步方法[J]. 交通运输工程学报, 2022, 22(3):

- 199-209.
- QIU W Z, SHANG G W, CHAI L G, et al. Synergy twin car road simulation test oriented synchronous multi-scale filtering method [J]. *Journal of Transportation Engineering*, 2022, 22 (3): 199-209.
- [8] 闵海根, 李尧, 汪建球, 等. 考虑通信时延的智能网联汽车协同定位方法[J]. *中国公路学报*, 2023, 36(6): 220-234.
- MIN H G, LI Y, WANG J Q, et al. Cooperative localization method for connected and autonomous vehicles considering communication delay [J]. *China Journal of Highway and Transport*, 2023, 36(6): 220-234.
- [9] 张红娟, 钱闯, 招倩莹, 等. 顾及通信延迟的车路协同高精度定位[J/OL]. *测绘学报*: 1-29[2024-01-09].
- ZHANG H J, QIAN C, ZHAO Q Y, et al. Take into account the communication latency car road together high-precision positioning [J/OL]. *Acta Geodaetica et Cartographica Sinica*: 1-29 [2024-01-09].
- [10] 刘经南, 詹骄, 郭迟, 等. 智能高精地图数据逻辑结构与关键技术[J]. *测绘学报*, 2019, 48(8): 939-953.
- LIU J N, ZHAN J, GUO C, et al. Data logic structure and key technologies on intelligent high-precision map [J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(8): 939-953.
- [11] JIANG K, YANG D G, LIU C R, et al. A flexible multi-layer map model designed for lane-level route planning in autonomous vehicles [J/OL]. *Engineering*. <https://doi.org/10.1016/j.eng.2018.11.032>.
- [12] XU L, ZHUANG W, YIN G, et al. Geometry-based cooperative localization for connected vehicle subject to temporary loss of GNSS signals [J]. *IEEE Sensors Journal*, 2021, 21(20): 23527-23536.
- [13] ZHANG G H, NG H F, WEN W S, et al. 3D mapping database aided gnss based collaborative positioning using factor graph optimization [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 22(10): 6175-6187.
- [14] VALGREN C, LILIENTHAL A J. SIFT, SURF & seasons: appearance-based long-term localization in outdoor environments [J]. *Robotics and Autonomous Systems*, 2010, 58(2): 149-156.
- [15] 邓泽武, 胡钊政, 周哲, 等. 融合激光雷达与双层地图模型的智能车定位[J]. *汽车工程*, 2022, 44(7): 1018-1026.
- DENG Z W, HU Z Z, ZHOU Z, et al. Intelligent vehicle positioning by fusing LiDAR and double-layer map model [J]. *Automotive Engineering*, 2022, 44(7): 1018-1026.
- [16] 张小俊, 奚敬哲, 史延雷, 等. 面向路侧视角目标检测的轻量级 YOLOv7-R 算法 [J]. *汽车工程*, 2023, 45(10): 1833-1844.
- ZHANG X J, XI J Z, SHI Y L, et al. Lightweight YOLOv7-R algorithm for road-side view target detection [J]. *Automotive Engineering*, 2023, 45(10): 1833-1844.
- [17] 徐国艳, 牛欢, 郭宸阳, 等. 基于三维激光点云的目标识别与跟踪研究 [J]. *汽车工程*, 2020, 42(1): 38-46.
- XU G Y, NIU H, GUO C Y, et al. Research on target recognition and tracking based on 3D laser point cloud [J]. *Automotive Engineering*, 2020, 42(1): 38-46.
- [18] HUANG K, HAO Q. Joint multi-object detection and tracking with Camera-LiDAR fusion for autonomous driving [C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2021: 6983-6989.
- [19] 余世明, 周景远, 何德峰, 等. 随机有界通信时延下传感器网络中的一致性时钟同步算法 [J]. *控制与决策*, 2020, 35(5): 1159-1166.
- YU S M, ZHOU J Y, HE D F, et al. Sensor network under random communication time delay bounded consistency in the clock synchronization algorithm [J]. *Control and Decision*, 2020, 35(5): 1159-1166.
- [20] 陶倩文, 胡钊政, 万金杰, 等. 基于点云极化表征与孪生网络的智能车定位 [J]. *电子与信息学报*, 2023, 45(4): 1163-1172.
- TAO Q W, HU Z Z, WAN J J, et al. Intelligent vehicle localization based on polarized LiDAR representation and siamese network [J]. *Journal of Electronics & Information Technology*, 2023, 45(4): 1163-1172.