

## 基于车辆与车辆的车联网分布式协同感知定位

谯小康, 屈小媚<sup>†</sup>

(西南民族大学 计算机系统国家民委重点实验室, 四川 成都 610041)

**摘要:** 车辆协同感知定位是车辆定位的热点技术。针对车载自组织网络, 本文在GPS卫星导航和车辆自身航位推算(DR)的基础上, 利用车辆之间的到达时间(TOA)观测和车辆到车辆(V2V)的实时通信来设计一种分布式协同定位方法。针对协同定位中TOA测量函数的非线性和辅助车辆真实位置未知的问题, 提出了一种基于改进无迹卡尔曼滤波(UKF)的协同定位算法。相对于传统的UKF协同定位使用GPS观测值作为辅助车辆位置, 本文提出的算法将辅助车辆位置作为未知参数, 扩维到状态向量, 有效降低了辅助车辆位置误差对定位精度的影响。Monte Carlo仿真结果表明, 利用TOA观测的协同定位精度明显优于仅利用GPS和DR的独立定位精度, 且改进的UKF协同定位算法相比于传统UKF算法, 具有更高的定位性能。

**关键词:** 车载自组织网络; 到达时间; 车辆到车辆; 协同定位; 无迹卡尔曼滤波

**引用格式:** 谯小康, 屈小媚. 基于车辆与车辆的车联网分布式协同感知定位. 控制理论与应用, 2021, 38(7): 988 – 996

DOI: 10.7641/CTA.2021.00693

## Vehicle to vehicle-based distributed cooperative sensing positioning for internet of vehicles

QIAO Xiao-kang, QU Xiao-mei<sup>†</sup>

(The Key Laboratory for Computer Systems of State Ethnic Affairs Commission,  
Southwest Minzu University, Chengdu Sichuan 610041, China)

**Abstract:** Vehicle cooperative sensing positioning is a hot technology of vehicle positioning. This paper explores the distribute cooperative positioning problem by incorporating the time of arrival (TOA) observations into the GPS satellite navigation and vehicle's own dead reckoning (DR) information for the vehicular Ad-hoc Networks. In the proposed distribute cooperative positioning method, an improved unscented Kalman filtering (UKF) algorithm is designed to deal with the nonlinearity of the TOA measurement function as well as the inaccurate locations of the auxiliary vehicles. In comparison with the traditional UKF cooperative positioning method, which uses the GPS observation as the corresponding auxiliary vehicle location, the proposed algorithm takes the auxiliary vehicle locations as unknown parameters and extends the dimension of the state vector, therefore, the influence of the location errors in the auxiliary vehicles is effectively reduced. Monte Carlo simulation results show that the cooperative positioning accuracy by incorporating the TOA information is obviously better than that of the independent positioning using only GPS and DR, and the performance of the improved UKF cooperative positioning algorithm is considerably more accurate than that of the traditional UKF algorithm.

**Key words:** vehicular ad-hoc networks; time of arrival; vehicle-to-vehicle; cooperative positioning; unscented Kalman filter

**Citation:** QIAO Xiaokang, QU Xiaomei. Vehicle to vehicle-based distributed cooperative sensing positioning for internet of vehicles. *Control Theory & Applications*, 2021, 38(7): 988 – 996

### 1 引言

随着城市化进程的不断推进, 车辆基数的高速增长导致交通问题日益突出。车辆定位技术作为智能交通系统的核心技术, 受到国内外学者的高度重视<sup>[1]</sup>。

基于车联网的定位技术主要包括差分定位<sup>[2]</sup>(differential positioning, DP)技术与协同定位<sup>[3]</sup>(cooperative positioning, CP)技术。由于多路径效应<sup>[4]</sup>的存在, 在城市环境下DP技术无法实现定位精度提升, 文[5]中的

收稿日期: 2020–10–13; 录用日期: 2021–02–26.

<sup>†</sup>通信作者. E-mail: Maths.girl@163.com.

本文责任编辑: 张承慧。

国家自然科学基金项目(61873217), 西南民族大学研究生创新型科研项目(CX2020SZ09)资助。

Supported by the National Natural Science Foundation of China (61873217) and the Innovative Scientific Research Projects for Graduate Students of Southwest Minzu University (CX2020SZ09).

实验结果也验证了这一结论。图1展示了一种GPS(global positioning system)卫星信号受到多路径效应导致反射、阻隔的场景。协同定位是近几年来国内外研究热点<sup>[6-8]</sup>。基于车联网的协同定位是指车辆通过车路协同系统(vehicle to everything, V2X)进行信息交换融合定位, 其通信方式主要包括车辆与车辆(vehicle to vehicle, V2V)、车辆与路边节点(vehicle to infrastructure, V2I)以及车辆与行人(vehicle to pedestrian, V2P), 融合的信息包括到达角度(angle of arrival, AOA)、到达时间(time of arrival, TOA)、接收信号强度(received signal strength, RSS)、载波频率偏移(carrier frequency offset, CFO), 或这些测量的混合<sup>[9-11]</sup>。协同定位并不局限于车辆应用, 也被应用于其他具有或不具有移动性的传感器网络<sup>[12-14]</sup>。

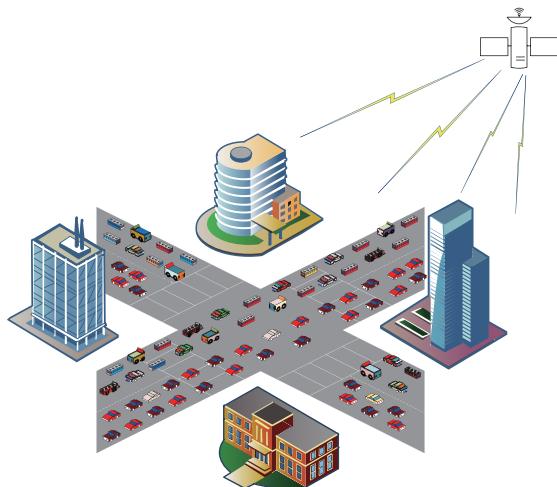


图1 多路径效应场景

Fig. 1 Multipath effect scenario

为处理GPS多路径问题, 基于车联网V2X通信的协同定位可有效增强GPS的定位精度<sup>[15-17]</sup>。文[17]中, 待估车辆利用V2X来获取辅助车辆以及路边节点的位置信息, 采用3个滤波器结构, 选取最优效果作为主滤波器, 一定程度上改进了车辆定位精度。然而, 该方法路边节点位置信息丢失时定位性能一般, 且采用3个滤波器造成计算资源浪费。另一方面, 依赖于V2I通信的协同定位需要沿路安装基础设施, 其成本过高不易实现。最近, 文[18]提出利用V2P测得车辆到行人的距离信息, 从而改进GPS的定位精度。然而, 由于行人是非协作地被动定位, 在行人数量较多的情况下, 难以对V2P观测进行准确的数据关联。

因此, 本文考虑在基于V2V的车载自组织网络中, 利用GPS、航位推算DR(dead reckoning)以及车辆之间的TOA测量进行分布式协同定位。DR是一种独立定位技术, 它依靠传感器来获取车辆的位移和航向等信息, 成本低且易于实现, 其定位误差随着时间推移不断累积<sup>[19]</sup>与GPS有很强的互补关系。在V2V场景下对于每个车辆而言, 既是待估车辆, 同时又是其他车

辆的辅助车辆。由于TOA是非线性测量, 一些方法用扩展卡尔曼滤波(extended Kalman filter, EKF)来预处理TOA观测<sup>[20]</sup>, 以获得动态定位。然而, 由于EKF基于非线性系统的一阶泰勒近似来传递观测的均值和协方差, 在一阶近似误差较大的情况下, 其定位性能不能取得很好的效果。

无迹卡尔曼滤波(unscented Kalman filter, UKF)<sup>[21]</sup>是另一种广泛应用的非线性滤波方法。UKF的基本原理是无迹变换(unscented transform, UT)。首先生成一组sigma点, 然后将系统非线性函数应用于每个sigma点, 得到变换后的向量。最后, 变换向量的样本均值和样本协方差给出真实均值和协方差的估计。理论上, 如果系统非线性函数完全确定, 即不含未知变量, UKF能达到非线性系统的二阶近似精度。

然而, 在本文的V2V协同定位场景中, TOA测量函数既是待估车辆位置的非线性函数, 也是辅助车辆位置的非线性函数。辅助车辆的真实位置是未知的, 因此非线性TOA测量函数包含未知的随机参数, 转换sigma点的步骤不可直接实现。克服这一困难的传统UKF方法是在转换sigma点过程中直接使用GPS观测。注意到GPS观测存在观测误差, 这将导致相应的无迹变换中的误差增大, 特别是在GPS定位误差较大的情况下。

文[22]提出了一种改进的UKF算法, 通过将随机参数扩维到状态向量来提升算法性能。理论分析证明, 在非线性系统中噪声概率密度函数是正态分布的情况下, 通过改进的UT变换得到的近似均值和协方差具有三阶近似精度。因此, 本文将辅助车辆的位置信息作为随机参数扩维到状态向量, 建立扩维后的运动模型。在相应的改进无迹变换中, 由于状态向量的维数增加, 使得sigma点的数目增大。此外, 每个改进的sigma点都包含待估车辆状态和辅助车辆的位置, 因此在转换sigma点的步骤中, 非线性TOA测量函数不再含有未知参数。虽然改进的UKF方法具有更高的计算复杂度, 但与传统UKF方法相比, 其估计性能明显提高, 如Monte Carlo仿真所示。

论文的其余结构安排如下, 第2节描述了车联网的分布式协同定位模型。第3节介绍了传统UKF与改进UKF下的协同定位算法。第4节提供了车辆直线行驶下和环线行驶下的Monte Carlo数值模拟结果, 第5节给出了本文的结论。

## 2 车联网协同定位模型

考虑某段道路上的车载自组织网络由 $n$ 个车辆节点组成, 每个车辆都可通过车载自组织网络与辅助车辆进行V2V实时通信。一个典型的协同定位场景如图2所示。考虑各车辆利用GPS, DR以及车辆之间的TOA测量进行协同定位。文献[23]指出基于TOA的二

维目标定位需要至少3个辅助平台,因此本文假设车辆的数量 $n \geq 4$ . 假设各车辆的真实位置分布在一个二维平面上, 车辆 $i$ ( $i = 1, \dots, n$ )在 $k$ 时刻的状态向量记为 $\mathbf{X}_k^i = [x_k^i \ y_k^i \ vx_k^i \ vy_k^i \ ax_k^i \ ay_k^i]^\top \in \mathbb{R}^6$ , 其中符号“ ${}^t$ ”表示转置,  $x_k^i, y_k^i$ 和 $vx_k^i, vy_k^i$ 分别表示车辆位置与速度矢量,  $ax_k^i, ay_k^i$ 为其加速度.

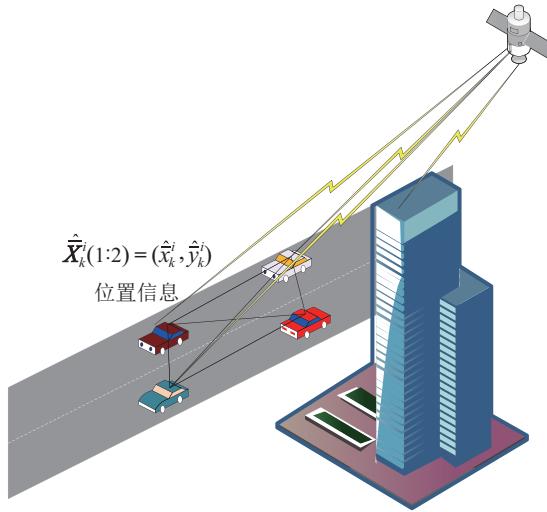


图2 车辆协同定位场景

Fig. 2 Vehicle co-positioning scenario

本文所涉及的公式符号较多, 为方便阅读给出了如表1所示的部分符号说明.

表1 符号说明  
Table 1 Symbol description

$\mathbf{X}_k^i$	第 <i>i</i> 辆车 <i>k</i> 时刻的状态向量
$\mathbf{Z}_k^i$	第 <i>i</i> 辆车 <i>k</i> 时刻的GPS观测向量
$\mathbf{F}$	DR状态转移矩阵
$\mathbf{G}$	DR误差转移矩阵
$\mathbf{H}$	GPS观测矩阵
$\mathbf{Q}_\omega$	DR误差协方差矩阵
$\mathbf{Q}_t$	TOA观测的误差协方差矩阵
$t_k^{(i)}$	<i>k</i> 时刻第 <i>i</i> 辆车与车辆 <i>l</i> 的TOA观测
$\mathbf{t}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 的TOA观测向量
$\mathbf{X}_k^l$	<i>k</i> 时刻待估车辆 <i>l</i> 的状态向量
$\hat{\mathbf{X}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 扩维后的状态向量
$\tilde{\mathbf{t}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 扩维后的TOA观测向量
$\bar{\mathbf{P}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 扩维后协方差矩阵
$\mathbf{X}_k^\theta$	<i>k</i> 时刻辅助车辆的位置向量
$\mathbf{P}_k^\theta$	<i>k</i> 时刻辅助车辆的协方差矩阵
$\check{\mathbf{X}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 数据传输后的状态向量
$\check{\mathbf{P}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 数据传输后的协方差矩阵
$\hat{\mathbf{X}}_{k k-1}^l$	<i>k</i> 时刻车辆 <i>l</i> 状态向量的先验估计
$\bar{\mathbf{P}}_{k k-1}^l$	<i>k</i> 时刻向量 $\hat{\mathbf{X}}_{k k-1}^l$ 的协方差矩阵
$\hat{\mathbf{t}}_{k k-1}^l$	<i>k</i> 时刻车辆 <i>l</i> 的TOA观测向量的先验估计
$\bar{\mathbf{P}}_k^{l,t}$	<i>k</i> 时刻向量 $\hat{\mathbf{t}}_{k k-1}^l$ 的协方差矩阵
$\bar{\mathbf{P}}_k^{l,xt}$	<i>k</i> 时刻向量 $\hat{\mathbf{X}}_{k k-1}^l$ 与向量 $\hat{\mathbf{t}}_{k k-1}^l$ 的协方差矩阵
$\hat{\mathbf{X}}_k^l$	<i>k</i> 时刻车辆 <i>l</i> 扩维后状态向量的后验估计

实际应用中, 每个车辆的真实位置信息均未知, 但可通过GPS卫星导航系统得到位置信息的一个实时观测, 其观测模型为

$$\mathbf{Z}_k^i = \mathbf{X}_k^i(1:2) + \boldsymbol{\nu}_k^i, \quad (1)$$

其中:  $\mathbf{Z}_k^i$ 表示车辆*i*在*k*时刻的GPS观测,  $\boldsymbol{\nu}_k^i$ 为观测误差, 假设其服从具有协方差为 $\mathbf{R}$ 的零均值高斯正态分布.

另一方面, 各车辆自带的惯性导航系统可用于DR航位推算. 基于DR和GPS信息融合的车辆定位可以描述为如下的线性系统

$$\begin{cases} \mathbf{X}_k^i = \mathbf{F}\mathbf{X}_{k-1}^i + \mathbf{G}\boldsymbol{\omega}_{k-1}, \\ \mathbf{Z}_k^i = \mathbf{H}\mathbf{X}_k^i + \boldsymbol{\nu}_k^i, \end{cases} \quad (2)$$

其中: 矩阵 $\mathbf{F}, \mathbf{G}$ 为状态方程参数, 观测矩阵

$$\mathbf{H} = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \end{pmatrix}, \quad (3)$$

向量 $\boldsymbol{\omega}_{k-1}$ 是零均值高斯白噪声, 其协方差矩阵记为 $\mathbf{Q}_\omega = \sigma_\omega^2 \mathbf{I}$ . 该线性系统可直接应用著名的Kalman滤波算法进行迭代预测.

本文的目的在于, 在车辆GPS观测和DR动态运动模型的基础上, 结合车载自组织网络中的TOA观测和V2V信息传输, 实现各车辆动态定位精度的提升. 在下文中, 对待估车辆*l*的状态记为 $\mathbf{X}_k^l$ , 其辅助车辆*i*( $i \neq l$ )的位置信息为 $\mathbf{X}_k^i$ .

待估车辆*l*与辅助车辆*i*之间的TOA观测数学模型可以描述为

$$t_k^{l(i)}(\mathbf{X}_k^l) = \|\mathbf{X}_k^l(1:2) - \mathbf{X}_k^i(1:2)\|/c + \Delta t_k^{l(i)}, \quad (4)$$

其中:  $c$ 为信号的传播速度,  $\Delta t_k^{l(i)}$ 为零均值高斯白噪声. 待估车辆*l*的TOA观测向量可以表示为

$$\mathbf{t}_k^l = [t_k^{l(1)}(\mathbf{X}_k^l) \ \cdots \ t_k^{l(l-1)}(\mathbf{X}_k^l) \ t_k^{l(l+1)}(\mathbf{X}_k^l) \ \cdots \ t_k^{l(n)}(\mathbf{X}_k^l)], \quad (5)$$

其观测误差向量的协方差矩阵记为 $\mathbf{Q}_t$ .

本文考虑对车载自组织网络中的每个待估车辆*l*, 利用测距雷达获取其辅助车辆的TOA观测, 利用V2V信息传输获取辅助车辆的位置信息, 并结合自身的DR动态运动模型, 来设计一种改进的无迹卡尔曼滤波器. 该滤波器的创新点在于充分考虑了辅助车辆位置的不确定性, 从而提高滤波性能.

各车辆节点均利用本文提出的改进无迹卡尔曼滤波器进行分布式计算, 得到自己及其辅助车辆的位置估计, 然后各车辆将计算得到的估计值通过V2V通信进行信息传输, 其信息传输方式如图3所示.

图3给出*a, b, c*辆车在协同定位过程中的信息流向, 图中实线表示*k*-1时刻的信息流向, 3辆车两两互相传输信息 $\mathbf{I}_{k-1}^i = (\hat{\mathbf{X}}_{k-1}^i, \bar{\mathbf{P}}_{k-1}^i), i = a, b, c$ , 其中

$\hat{\mathbf{X}}_{k-1}^i$ 为 $k-1$ 时刻车辆*i*的位置估计,  $\bar{\mathbf{P}}_{k-1}^i$ 为 $k-1$ 时刻车辆*i*的位置估计的协方差矩阵。

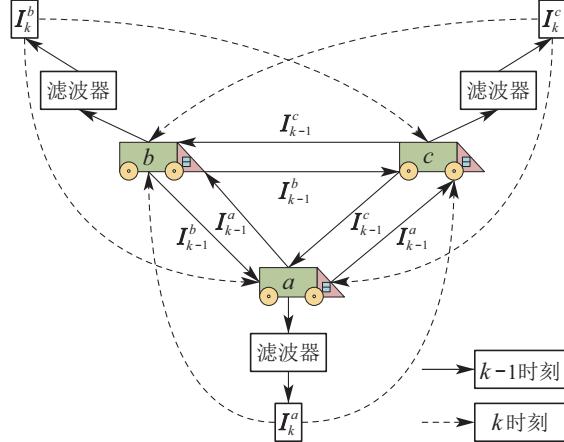


图3 车辆协同定位信息流向

Fig. 3 Information flow of co-positioning

每辆车将收到的信息通过滤波器进行数据融合得到 $k$ 时刻的信息, 然后通过如虚线所示信息流向将下一刻的状态向量以及协方差传输给邻近车辆, 从而实现分布式协同定位。

### 3 协同定位算法

#### 3.1 UKF协同定位算法

在车联网协同定位模型中, TOA观测向量 $\mathbf{t}_k$ 相对于状态向量 $\mathbf{X}_k$ 以及辅助车辆的真实位置均是非线性的。对于传统的UKF方法而言, 可以利用辅助车辆的GPS观测值作为辅助车辆位置的估计, 因此待估车辆的定位问题可以描述为如下的离散时间非线性系统:

$$\begin{cases} \mathbf{X}_k^l = \mathbf{F}\mathbf{X}_{k-1}^l + \mathbf{G}\omega_{k-1}, \\ \mathbf{t}_k^l = h(\mathbf{X}_k^l) + \Delta\mathbf{t}_k^l, \end{cases} \quad (6)$$

其中:  $\mathbf{X}_k^l = [x_k^l \ y_k^l \ vx_k^l \ vy_k^l \ ax_k^l \ ay_k^l]'$ 为第*l*辆车在 $k$ 时刻的状态向量,  $x_k^l$ ,  $y_k^l$ 和 $vx_k^l$ ,  $vy_k^l$ 分别表示车辆位置与速度矢量,  $ax_k^l$ ,  $ay_k^l$ 为其加速度。 $\mathbf{t}_k^l$ 为TOA测量的观测向量, 非线性的观测函数 $h(\mathbf{X}_k^l)$ 为

$$h(\mathbf{X}_k^l) = \begin{bmatrix} \sqrt{(x_k^1 - x_k^l)^2 + (y_k^1 - y_k^l)^2} \\ \vdots \\ \sqrt{(x_k^{l-1} - x_k^l)^2 + (y_k^{l-1} - y_k^l)^2} \\ \sqrt{(x_k^{l+1} - x_k^l)^2 + (y_k^{l+1} - y_k^l)^2} \\ \vdots \\ \sqrt{(x_k^n - x_k^l)^2 + (y_k^n - y_k^l)^2} \end{bmatrix}. \quad (7)$$

对于传统的无迹卡尔曼滤波先初始化状态向量和协方差, 然后生成sigma点并加权求和预测状态向量的均值和先验协方差。根据得到的先验协方差生成新的sigma点, 并加权求和预测观测向量的均值和协方差以及状态向量均值与观测向量均值之间的协方差。

值得注意的是在对观测向量进行预测时没有辅助车辆的真实位置, 这里使用辅助车辆GPS位置代替真实位置进行预测估计。最后, 使用标准卡尔曼滤波进行状态估计的预测更新。

#### 3.2 改进UKF分布式协同定位算法

注意到观测方程(4)中, TOA测量函数既是待估车辆位置的非线性函数, 也是辅助车辆位置的非线性函数。上一小节中的传统UKF方法使用GPS观测来代替辅助车量的真实位置。在本小节中, 将提出一种改进的无迹卡尔曼滤波方法。通过分析辅助车辆的真实位置与待估车辆真实位置都不可获得, 为了处理这种情况, 将辅助车辆的位置扩维到状态向量上, 如下所示:

$$\bar{\mathbf{X}}_k^l = [\mathbf{X}_k^l \ \mathbf{X}_k^\theta] \in \mathbb{R}^{2n+4}, \quad (8)$$

其中 $\mathbf{X}_k^\theta$ 为所有辅助车辆的位置向量

$$\mathbf{X}_k^\theta = [\mathbf{X}_k^1(1 : 2) \cdots \mathbf{X}_k^{l-1}(1 : 2)],$$

$$[\mathbf{X}_k^{l+1}(1 : 2) \cdots \mathbf{X}_k^n(1 : 2)] \in \mathbb{R}^{2n-2}. \quad (9)$$

扩维后的运动和观测模型可以描述为

$$\begin{cases} \bar{\mathbf{X}}_k^l = \bar{\mathbf{F}}\bar{\mathbf{X}}_{k-1}^l + \bar{\mathbf{G}}\omega_{k-1}, \\ \bar{\mathbf{t}}_k^l = h(\bar{\mathbf{X}}_k^l) + \nu_k, \end{cases} \quad (10)$$

其中:

$$\bar{\mathbf{F}} = \begin{pmatrix} \mathbf{F} & \mathbf{0} \\ \mathbf{0} & \mathbf{F}^\theta \end{pmatrix}, \quad \bar{\mathbf{G}} = \begin{pmatrix} \mathbf{G} \\ \mathbf{G}^\theta \end{pmatrix}. \quad (11)$$

协同定位中各车辆的初始状态值设定为

$$\begin{cases} \hat{\mathbf{X}}_0^i = E(\mathbf{X}_0^i), \quad i = 1, \dots, n, \\ \mathbf{P}_0^i = E[(\mathbf{X}_0^i - \hat{\mathbf{X}}_0^i)(\mathbf{X}_0^i - \hat{\mathbf{X}}_0^i)'], \end{cases} \quad (12)$$

扩维后系统(10)的初始状态记为

$$\begin{cases} \hat{\bar{\mathbf{X}}}_0^l = [\hat{\mathbf{X}}_0^l(1 : 6) \ \hat{\mathbf{X}}_0^1(1 : 2) \cdots \hat{\mathbf{X}}_0^{l-1}(1 : 2) \\ \quad \hat{\mathbf{X}}_0^{l+1}(1 : 2) \cdots \hat{\mathbf{X}}_0^n(1 : 2)], \\ \bar{\mathbf{P}}_0^l = \begin{pmatrix} \mathbf{P}_0^l & \mathbf{0} \\ \mathbf{0} & \mathbf{P}_0^\theta \end{pmatrix}, \end{cases} \quad (13)$$

其中 $\mathbf{P}_0^\theta$ 为辅助车辆位置向量的协方差矩阵。

在第 $k-1$ 步, 经过车联网V2V信息传输, 即图3中实线部分的信息传输, 扩维后系统(10)的初始状态更新为

$$\check{\bar{\mathbf{X}}}_{k-1}^l = [\hat{\bar{\mathbf{X}}}_{k-1}^l(1 : 6) \ \hat{\bar{\mathbf{X}}}_{k-1}^1(1 : 2) \cdots \hat{\bar{\mathbf{X}}}_{k-1}^{l-1}(1 : 2) \\ \quad \hat{\bar{\mathbf{X}}}_{k-1}^{l+1}(1 : 2) \cdots \hat{\bar{\mathbf{X}}}_{k-1}^n(1 : 2)], \quad (14)$$

及其协方差矩阵

$$\check{\bar{\mathbf{P}}}_{k-1}^l = \begin{pmatrix} \mathbf{P}_{k-1}^l & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \bar{\mathbf{P}}_{k-1}^1(1 : 2, 1 : 2) & \cdots & \mathbf{0} \\ \vdots & \vdots & & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \bar{\mathbf{P}}_{k-1}^n(1 : 2, 1 : 2) \end{pmatrix},$$

其中 $\bar{\mathbf{P}}_{k-1}^n(1 : 2, 1 : 2)$ 为协方差矩阵 $\bar{\mathbf{P}}_{k-1}^n$ 的第1,2行和第1,2列元素组成的矩阵。

基于扩维后的运动模型, 其sigma点的数量增加到 $2(2(n-1)+6)+1=4n+9$ , 生成的sigma点具体如下:

$$\begin{cases} \bar{\chi}_{k|k-1}^{l,0} = \check{\mathbf{X}}_{k|k-1}^l, \\ \bar{\chi}_{k|k-1}^{l,j} = \check{\mathbf{X}}_{k|k-1}^l + \tilde{\chi}_{k|k-1}^{l,j}, \quad j=1, \dots, 4n+8, \end{cases} \quad (15)$$

其中

$$\begin{cases} \tilde{\chi}_{k|k-1}^{l,j} = (\sqrt{(2n+4+\lambda)\bar{\mathbf{P}}_{k|k-1}^l})_j, \\ \tilde{\chi}_{k|k-1}^{l,2n+4+j} = -(\sqrt{(2n+4+\lambda)\bar{\mathbf{P}}_{k|k-1}^l})_j, \quad j=1, \dots, 2n+4, \end{cases} \quad (16)$$

参数 $\lambda$ 应满足 $2n+4+\lambda > 0$ , 相应的加权系数为

$$\begin{cases} \bar{W}^0 = \frac{\lambda}{2n+4+\lambda}, \\ \bar{W}^j = \frac{1}{2(2n+4+\lambda)}, \quad j=1, \dots, 4n+8, \end{cases} \quad (17)$$

通过DR动态运动模型对各sigma点进行预测, 并预测状态向量的均值

$$\begin{cases} \hat{\mathbf{X}}_{k|k-1}^{l,j} = \bar{\mathbf{F}}\bar{\chi}_{k|k-1}^{l,j}, \quad j=0, \dots, 4n+8, \\ \hat{\mathbf{X}}_{k|k-1}^l = \sum_{j=0}^{4n+8} \bar{W}^j \hat{\mathbf{X}}_{k|k-1}^{l,j}, \end{cases} \quad (18)$$

相应的先验协方差为

$$\bar{\mathbf{P}}_{k|k-1}^l = \sum_{j=0}^{4n+8} \bar{W}^j (\hat{\mathbf{X}}_{k|k-1}^{l,j} - \hat{\mathbf{X}}_{k|k-1}^l)' + \bar{\mathbf{G}}\mathbf{Q}_\omega\bar{\mathbf{G}}'. \quad (19)$$

根据得到均值及协方差, 生成新的sigma点

$$\begin{cases} \bar{\chi}_{k|k-1}^{l,0} = \hat{\mathbf{X}}_{k|k-1}^{l,j}, \\ \bar{\chi}_{k|k-1}^{l,j} = \hat{\mathbf{X}}_{k|k-1}^{l,j} + \tilde{\chi}_{k|k-1}^{l,j}, \quad j=1, \dots, 4n+8, \end{cases} \quad (20)$$

其中

$$\begin{cases} \tilde{\chi}_{k|k-1}^{l,j} = (\sqrt{(2n+4+\lambda)\bar{\mathbf{P}}_{k|k-1}^l})_j, \\ \tilde{\chi}_{k|k-1}^{l,2n+4+j} = -(\sqrt{(2n+4+\lambda)\bar{\mathbf{P}}_{k|k-1}^l})_j, \quad j=1, \dots, 2n+4. \end{cases} \quad (21)$$

对于改进的无迹卡尔曼滤波而言, 每个sigma点都应该使用系统的非线性测量函数 $h(\bar{\mathbf{X}}_k)$ 进行变换, 因此转换后的sigma点计算如下:

$$\hat{\mathbf{t}}_{k|k-1}^{l,j} = h(\bar{\chi}_{k|k-1}^{l,j}), \quad j=0, \dots, 4n+8. \quad (22)$$

对 $\hat{\mathbf{t}}_{k|k-1}^{l,j}$ 进行带权求和, 得到观测量向量的预测值, 计算如下:

$$\hat{\mathbf{t}}_{k|k-1}^l = \sum_{j=0}^{4n+8} \bar{W}^j \hat{\mathbf{t}}_{k|k-1}^{l,j}, \quad (23)$$

预测向量 $\hat{\mathbf{t}}_{k|k-1}$ 协方差矩阵估计为

$$\bar{\mathbf{P}}_k^{l,t} = \sum_{j=0}^{4n+8} \bar{W}^j (\hat{\mathbf{t}}_{k|k-1}^{l,j} - \hat{\mathbf{t}}_{k|k-1}^l)' + \mathbf{Q}_t, \quad (24)$$

以及 $\hat{\mathbf{X}}_{k|k-1}^l$ 与 $\hat{\mathbf{t}}_{k|k-1}^l$ 之间的协方差矩阵估计为

$$\bar{\mathbf{P}}_k^{l,xt} = \sum_{j=0}^{4n+8} \bar{W}^j (\hat{\mathbf{X}}_{k|k-1}^{l,j} - \hat{\mathbf{X}}_{k|k-1}^l)' (\hat{\mathbf{t}}_{k|k-1}^{l,j} - \hat{\mathbf{t}}_{k|k-1}^l)', \quad (25)$$

然后, 可以使用标准卡尔曼滤波进行状态估计的预测更新, 如下所示:

$$\begin{cases} \bar{\mathbf{K}}_k^l = \bar{\mathbf{P}}_k^{l,xt} (\bar{\mathbf{P}}_k^{l,t})^{-1}, \\ \bar{\mathbf{P}}_k^l = \bar{\mathbf{P}}_{k|k-1}^l - \bar{\mathbf{K}}_k^l \bar{\mathbf{P}}_k^{l,t} (\bar{\mathbf{K}}_k^l)', \\ \hat{\mathbf{X}}_k^l = \hat{\mathbf{X}}_{k|k-1}^l + \bar{\mathbf{K}}_k^l (\bar{\mathbf{t}}_k^l - \hat{\mathbf{t}}_{k|k-1}^l). \end{cases} \quad (26)$$

为直观的理解整个算法的流程, 给出如下算法1所示的伪代码, 其中:  $N$ 表示采样次数,  $n$ 代表车辆总数.

**Algorithm 1 Improved UKF-based distributed CP algorithm**

**Input:**  $n, N, \mathbf{F}, \mathbf{G}, \mathbf{G}_x, \mathbf{P}_0, \mathbf{Q}_\omega, \mathbf{Q}_x, \mathbf{Q}_t, \hat{\mathbf{X}}_0^i, i=1, \dots, n;$

**Initialize:**  $\bar{\mathbf{F}} = [\mathbf{F}; 0; 0, \mathbf{F}^\theta], \bar{\mathbf{G}} = [\mathbf{G}; \mathbf{G}^\theta], \bar{\mathbf{P}}_0 = [\mathbf{P}_0; 0, \mathbf{P}^\theta];$

**Algorithm process:**

**for:**  $k = 1; k <= N; k++$  **do**

**for:**  $i = 1; i <= n; i++$  **do**

**Prediction:**

**for:**  $j = 1; j <= 4n+9; j++$  **do**  
calculate  $\tilde{\chi}_{k|k-1}^{i,j}, \bar{W}^j$  following (15)–(17);  
calculate  $\hat{\mathbf{X}}_{k|k-1}^{i,j}$  following (18);

**end for**

calculate  $\hat{\mathbf{X}}_{k|k-1}^i, \bar{\mathbf{P}}_{k|k-1}^i$  following (18) and (19);

**for:**  $j = 1; j <= 4n+9; j++$  **do**

calculate  $\tilde{\chi}_{k|k-1}^{i,j}$  following (20)(21);

**end for**

**for:**  $j = 1; j <= 4n+9; j++$  **do**

calculate  $\hat{\mathbf{t}}_{k|k-1}^{i,j}$  following (22);

**end for**

calculate  $\hat{\mathbf{t}}_{k|k-1}^i$  following (23);

calculate  $\bar{\mathbf{P}}_{k|k-1}^{i,t}, \bar{\mathbf{P}}_{k|k-1}^{i,xt}$  following (24) and (25);

**Update:**

update  $\bar{\mathbf{K}}_k^i, \bar{\mathbf{P}}_k^i, \hat{\mathbf{X}}_k^i$  following (26);

**end for**

**Data transmission**

**end for**

**Output:**  $\hat{\mathbf{X}}_k^i, i = 1, \dots, n, k = 1, \dots, N$ .

最后, 车联网中的车辆再进行如图3虚线部分所示的两两数据传输, 各车辆节点根据接收到的信息再进行下一步的分布式定位.

本文通过将TOA观测函数中辅助车辆位置扩维到状态向量来改进UKF中UT变换的近似精度. 传统的UKF滤波在UT变换过程中直接使用带噪声的GPS观测, 并忽略其观测误差, 这在理论上无法保证UT变换后的近似精度. 下面的引理在理论上保证了本文的改进UKF方法能达到非线性系统的三阶近似精度<sup>[22]</sup>.

**引理1** 对于具有对称概率密度函数的随机向量  $\mathbf{X}_k^l$ , 如果非线性函数  $t = h(\mathbf{X}_k^l, \mathbf{X}_k^\theta)$  包含未知随机参数  $\mathbf{X}_k^\theta$ , 则通过改进的无迹变换(23)–(24)得到的  $t$  的近似均值和协方差具有三阶近似精度.

#### 4 仿真实验与结果分析

在数值模拟实验中, 假设车载自组织网络中的车辆总数  $n = 4$ , 时间步长  $\delta_t = 0.2$  s, 采样点数为 100. 车辆机动参数设定为: 假设车载GPS定位误差方差为  $\sigma_x^2 = \sigma_y^2 = (5\sqrt{2}\text{m})^2$ , 里程计和陀螺仪测量误差方差分别为  $\sigma_s^2 = (0.1\text{m})^2$  和  $\sigma_\omega^2 = (0.005 \text{ rad/s})^2$ , 加速度误差方差为  $\sigma_{ax}^2 = \sigma_{ay}^2 = (0.3 \text{ m/s}^2)^2$ , 所有车辆都有V2V通信和TOA设备模块, TOA测量误差为零均值高斯白噪声, 其方差为  $(2s/c)^2$ ,  $c$  为信号的传播速度. 车辆定位精度由均方根误差来比较, 其定义为RMSE

$$= \sqrt{\sum_{m=1}^L \|\hat{\mathbf{X}}_k - \mathbf{X}_k\|^2 / L}, \text{ 其中 } L = 1000 \text{ 为Monte Carlo仿真次数.}$$

##### 4.1 仿真实验1

为验证本文提出的改进UKF的GPS/DR/TOA分布式协同定位方法的性能, 通过数值模拟实验比较了GPS定位、GPS/DR定位、UKF的GPS/DR/TOA协同定位以及改进UKF的GPS/DR/TOA协同定位4种方法在以速度  $v_x = v_y = 15 \text{ m/s}$  匀速直线行驶下位置估计的RMSE. 车辆的直线行驶轨迹如图4所示.

各车辆在4种方法下的RMSE展示在图5–8中. 从图5–8的结果可以看出单独GPS的定位效果是最差的, 定位精度只有  $4.9862 \text{ m}$ . 基于KF的GPS/DR定位能够很大程度上提高定位精度, 定位精度能够达到  $3.3977 \text{ m}$ . UKF的GPS/DR/TOA定位能够进一步的提高定位精度, 定位精度能够达到  $2.3723 \text{ m}$ . 改进UKF的GPS/DR/TOA定位能够更进一步的提高定位精度, 定位精度能够达到  $1.9743 \text{ m}$  左右.

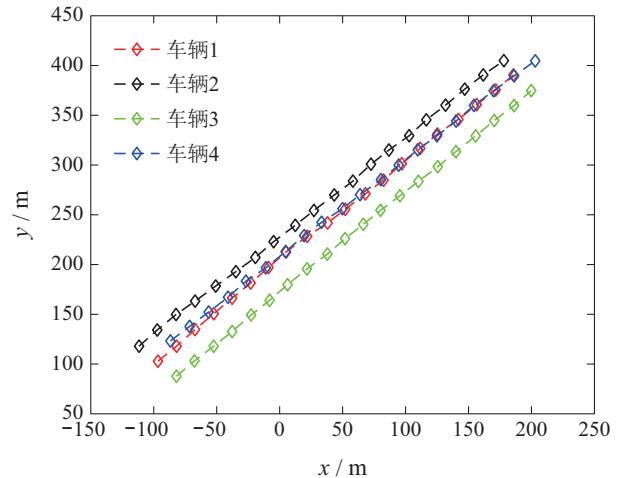


图4 直线行驶下的车辆轨迹

Fig. 4 Trajectory of vehicles with straight-line travel

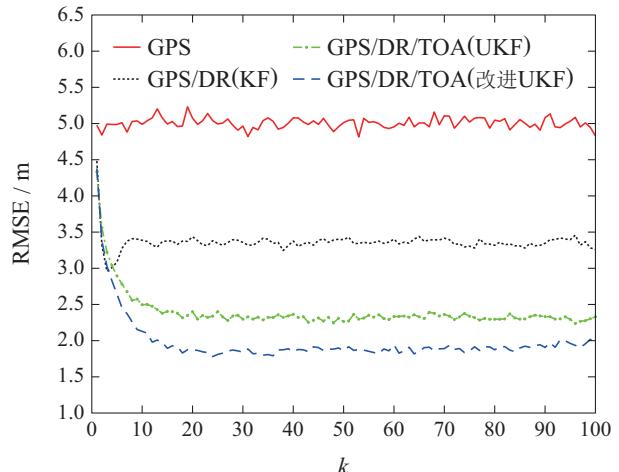


图5 直线行驶下车辆1位置估计的RMSE

Fig. 5 RMSE of location estimation for vehicle 1 with straight-line travel

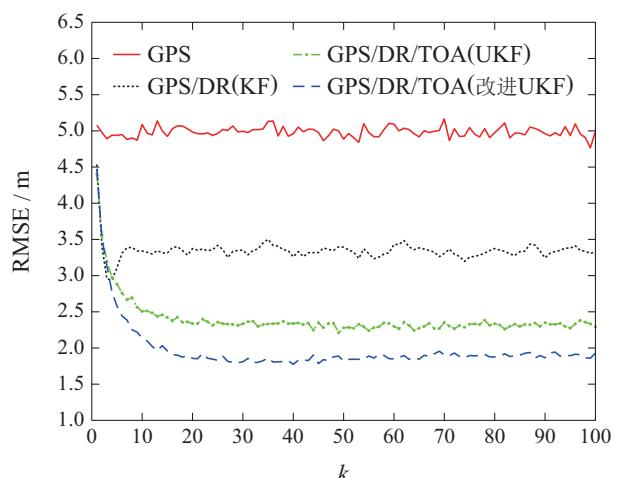


图6 直线行驶下车辆2位置估计的RMSE

Fig. 6 RMSE of location estimation for vehicle 2 with straight-line travel

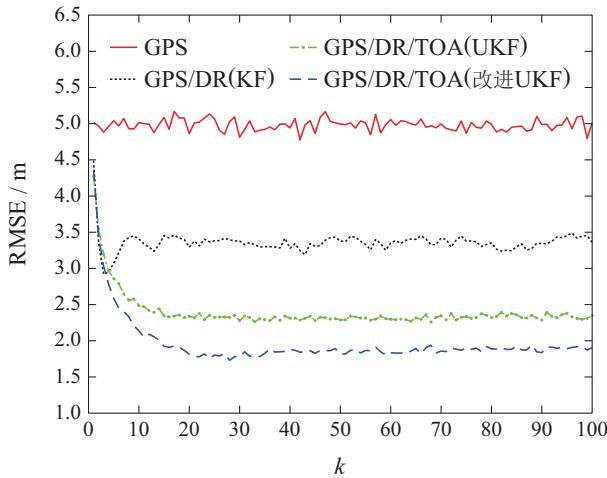


图 7 直线行驶下车辆3位置估计的RMSE

Fig. 7 RMSE of location estimation for vehicle 3 with straight-line travel

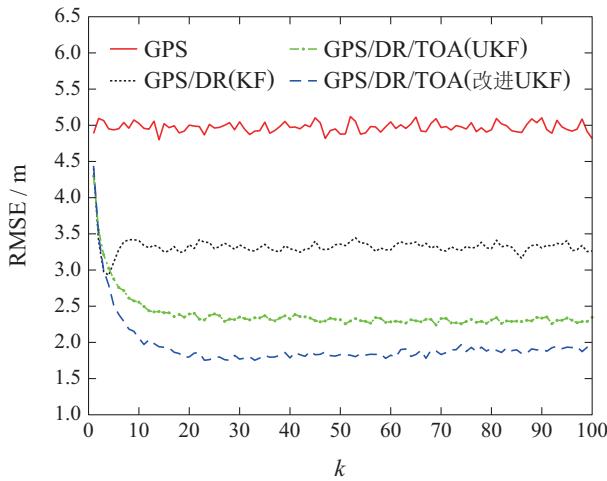


图 8 直线行驶下车辆4位置估计的RMSE

Fig. 8 RMSE of position estimation for vehicle 4 with straight-line travel

## 4.2 仿真实验2

为了进一步验证比较改进UKF的GPS/DR/TOA分布式协同定位方法的性能,再次比较了4种方法在环线行驶下位置估计的RMSE,环线行驶阶段可以分为4个阶段,其中4辆车行驶的第1阶段 $k = 1, \dots, 25$ 速度分别为

$$\begin{cases} vx_k^i = -(15 + i)\sqrt{2} \sin(k\varphi T) \text{ m/s}, \\ vy_k^i = (15 + i)\sqrt{2} \cos(k\varphi T) \text{ m/s}, \end{cases} \quad (27)$$

第2阶段 $k = 26, \dots, 50$ 速度分别为

$$\begin{cases} vx_k^i = -(15 + i)\sqrt{2} \sin(25\varphi T) \text{ m/s}, \\ vy_k^i = -(15 + i)\sqrt{2} \cos(25\varphi T) \text{ m/s}, \end{cases} \quad (28)$$

第3阶段 $k = 51, \dots, 75$ 速度分别为

$$\begin{cases} vx_k^i = -(15 + i)\sqrt{2} \sin((k - 25)\varphi T) \text{ m/s}, \\ vy_k^i = (15 + i)\sqrt{2} \cos((k - 25)\varphi T) \text{ m/s}, \end{cases} \quad (29)$$

第4阶段 $k = 76, \dots, 100$ 速度分别为

$$\begin{cases} vx_k^i = -(15 + i)\sqrt{2} \sin(50\varphi T) \text{ m/s}, \\ vy_k^i = (15 + i)\sqrt{2} \cos(50\varphi T) \text{ m/s}, \end{cases} \quad (30)$$

其中:  $i = 1, \dots, 4$ ,  $\varphi = 36 \text{ rad/s}$ , 加速度 $ax = vx'$ ,  $ay = vy'$ . 车辆的环线行驶轨迹如图9所示.

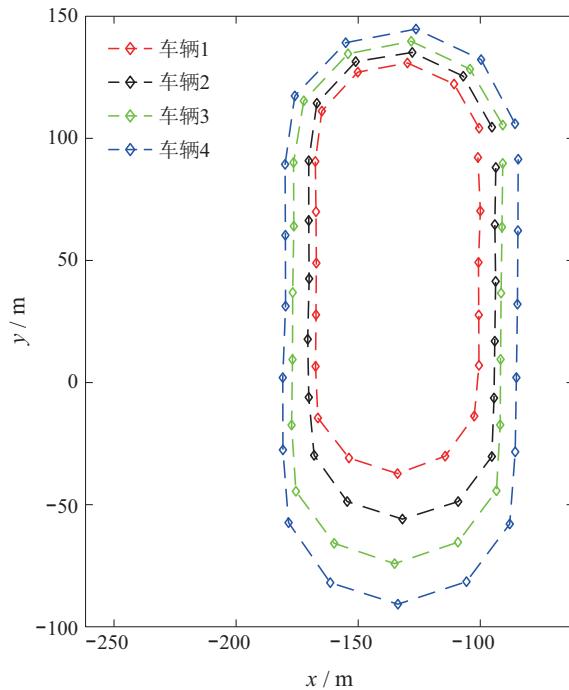


图 9 环线行驶下的车辆轨迹

Fig. 9 Trajectory of vehicles with ring-line travel

各车辆在4种方法下的RMSE展示在图10–13中.从图10–13的结果可以看出,单独的GPS定位效果是最差的,定位精度只有5.043 m. 基于KF的GPS/DR定位能够很大程度上提高定位精度,定位精度能够达到3.5962 m. UKF的GPS/DR/TOA定位能够进一步的提高定位精度,定位精度能够达到2.9228 m. 改进UKF的GPS/DR/TOA定位能够更进一步的提高定位精度,定位精度能够达到2.3468 m.

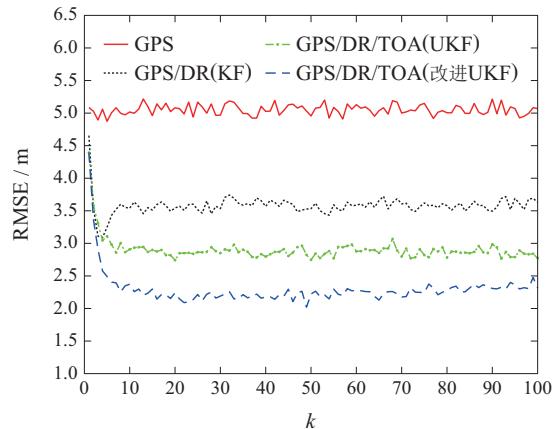


图 10 环线行驶下车辆1位置估计的RMSE

Fig. 10 RMSE of location estimation for vehicle 1 with ring-line travel

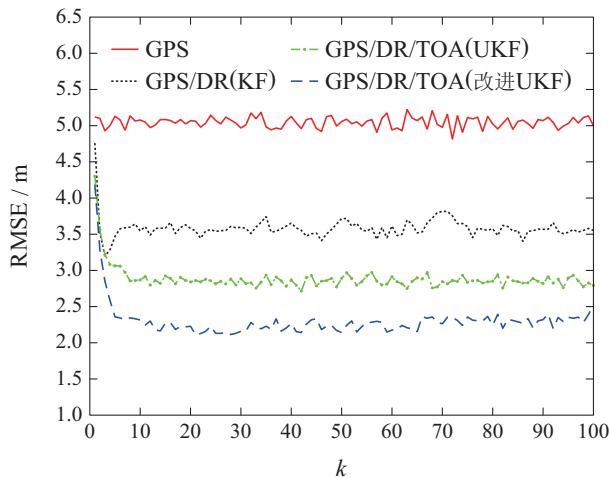


图 11 环线行驶下车辆2位置估计的RMSE

Fig. 11 RMSE of location estimation for vehicle 2 with ring-line travel

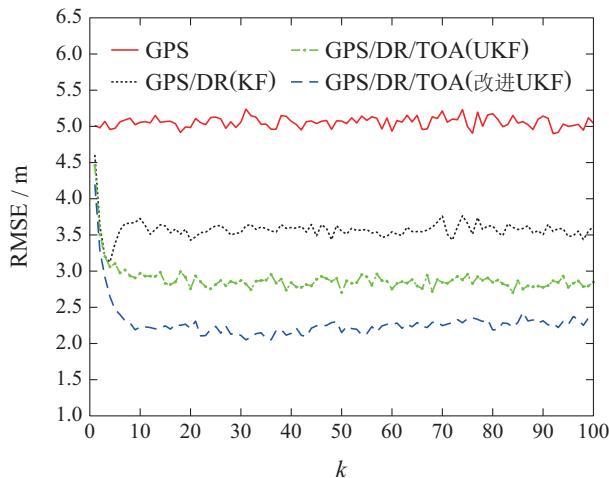


图 12 环线行驶下车辆3位置估计的RMSE

Fig. 12 RMSE of location estimation for vehicle 3 with ring-line travel

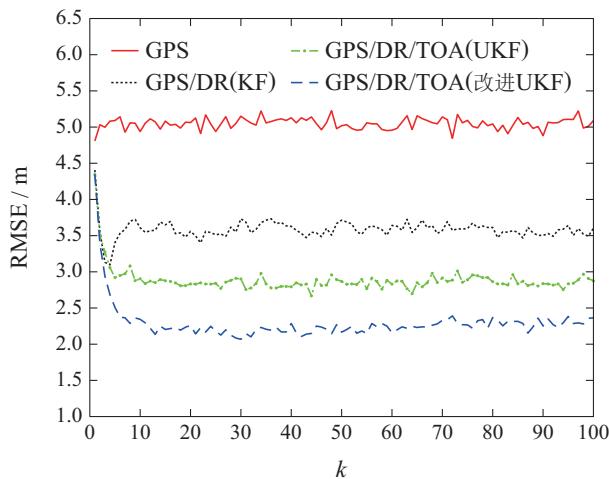


图 13 环线行驶下车辆4位置估计的RMSE

Fig. 13 RMSE of location estimation for vehicle 4 with ring-line travel

相对改善程度的指标:

$$\mu = \left(1 - \frac{\text{RMSE}_A}{\text{RMSE}_B}\right) \times 100\%, \quad (31)$$

其中:  $\text{RMSE}_A$  表示改进 UKF 的协同定位精度,  $\text{RMSE}_B$  表示其它方法的定位精度. 若  $\mu$  为正说明改进协同定位相较其它方法定位性能得到改善, 值越大说明改善的程度越高, 反之则说明性能恶化. 改进的 UKF 协同定位方法与独立的 GPS 定位和 GPS/DR 以及传统的 UKF 协同定位性能比较如表 2 所示, 结果表明在匀速直线行驶的情况下, 改进的 UKF 协同定位方法与独立的 GPS 定位和 GPS/DR 以及传统的 UKF 协同定位性能相比较, 性能分别提升了 60%, 42% 和 17%, 在环线行驶的情况下, 性能提升率分别为 53%, 35% 和 20%.

表 2 改进 UKF 协同定位的性能提升率

Table 2 Performance improvement rate of improved UKF co-positioning

定位方式	直线/环线	性能
	mean-RMSE	提升率/%
GPS	5.0/5.0	60/53
GPS/DR(KF)	3.4/3.6	42/35
GPS/DR/TOA(UKF)	2.4/2.9	17/20
GPS/DR/TOA(改进UKF)	2.0/2.3	—

## 5 总结

本文针对车辆定位场景中 GPS 信号容易受到多路径效应的影响, 在道路上修建路边节点成本过高等实际问题, 提出利用车载自组织网络中的 V2V 通信进行车辆分布式协同定位的问题. 在车辆之间的 TOA 观测模型中, 存在辅助车辆真实位置未知的问题, 本文提出的改进 UKF 协同定位方法通过将辅助车辆位置扩维到状态向量, 使得辅助车辆位置信息能够跟随待估车辆状态信息同步更新以提高定位性能. Monte Carlo 仿真结果表明, 改进的 UKF 分布式协同定位系统显著增强了车辆定位的精度.

## 参考文献:

- [1] CRUZ S B, ABRUDAN T E, XIAO Z, et al. Neighbor-aided localization in vehicular networks. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(10): 2693 – 2702.
- [2] ROHANI M, GINGRAS D, GRUYER D. A novel approach for improved vehicular positioning using cooperative map matching and dynamic base station DGPS concept. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(1): 230 – 239.
- [3] LIU J, CAI B G, WANG J. Cooperative localization of connected vehicles: integrating GNSS with DSRC using a robust cubature Kalman filter. *IEEE Transactions on Intelligent Transportation Systems*, 2017, 18(8): 2111 – 2125.
- [4] STRODE P R R, GROVES P D. GNSS multipath detection using three-frequency signal-to-noise measurements. *GPS Solutions*, 2016, 20(3): 399 – 412.

式(31)定义性能提升率参数  $\mu$ , 作为评价定位性能

- [5] ALAM N, BALAEI A T, DEMPSTER A G. Relative positioning enhancement in VANETs: a tight integration approach. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(1): 47–55.
- [6] LIU K, LIM H B, FRAZZOLI E, et al. Improving positioning accuracy using GPS pseudorange measurements for cooperative vehicular localization. *IEEE Transactions on Vehicular Technology*, 2014, 63(6): 2544–2556.
- [7] KUUTTI S, FALLAH S, KATSAROS K, et al. A survey of the state-of-the-art localization techniques and their potentials for autonomous vehicle applications. *IEEE Internet of Things Journal*, 2018, 5(2): 829–846.
- [8] LIU Siyuan. *Research of adaptive cooperative positioning technology for vehicular network*. Shanghai Jiao Tong University, 2019.  
(刘思源. 车联网自适应协同定位技术的研究. 上海交通大学, 2019.)
- [9] GUO Yunfei, PAN Jinxing, CAI Zhi. Passive coherent location with multi-scan clutter sparsity estimation. *Control Theory & Applications*, 2018, 35(7): 981–987.  
(郭云飞, 潘金星, 才智. 基于多帧杂波稀疏度估计的无源协同定位. 控制理论与应用, 2018, 35(7): 981–987.)
- [10] QU Xiaomei, LIU Tao, TAN Wenrong. Multi-source passive localization via multiple unmanned aerial vehicles. *Scientia Sinica Informationis*, 2019, 49(5): 570–584.  
(屈小媚, 刘韬, 谈文蓉. 基于多无人机协作的多目标无源定位算法. 中国科学: 信息科学, 2019, 49(5): 570–584.)
- [11] LU Jian, CHEN Xu, LIU Tong, et al. Simultaneous localization and tracking algorithm utilizing FastSLAM framework for autonomous underwater vehicles. *Control Theory & Applications*, 2020, 37(1): 89–97.  
(卢健, 陈旭, 刘通, 等. 利用FastSLAM框架的多自治水下航行器同时定位与跟踪算法. 控制理论与应用, 2020, 37(1): 89–97.)
- [12] WANG G, LI Y. A semidefinite relaxation method for source localization using TDOA and FDOA measurements. *IEEE Transactions on Vehicular Technology*, 2013, 62(2): 853–862.
- [13] WANG G, CAI S, LI Y. A bias-reduced nonlinear WLS method for TDOA/FDOA-based source localization. *IEEE Transactions on Vehicular Technology*, 2016, 65(10): 8603–8615.
- [14] LI Xiaosha. *Collaborative location and tracking technology based on TDOA/FDOA/AOA*. Southwest Jiaotong University, 2017.  
(李晓莎. 基于时频差及测向的协同定位跟踪技术研究. 西南交通大学, 2017.)
- [15] DUAN Xuting, TIAN Daxin, WANG Yunpeng. Vehicle cooperative positioning enhancement method based on V2X communication networks. *Automotive Engineering*, 2019, 49: 570–584, DOI: 10.1360/N112018–00341.  
(段续庭, 田大新, 王云鹏. 基于V2X通信网络的车辆协同定位增强方法. 汽车工程, 2019, 49: 570–584, DOI: 10.1360/N112018–00341.)
- [16] SCHWARZBACH P, MICHLER A, TAUSCHER P, et al. An empirical study on V2X enhanced low-cost GNSS cooperative positioning in urban environments. *Sensors*, 2019, 19(23): 5201.
- [17] WANG Jiuling, WU Shaobo, ZHANG Yuanli, et al. Cooperative vehicle positioning method based on V2X enhanced GPS. *Journal of System Simulation*, 2019, 31(12): 347–352.  
(王玖玲, 吴韶波, 张媛利, 等. 利用V2X增强GPS的协同车辆定位方法. 系统仿真学报, 2019, 31(12): 347–352.)
- [18] BRABILLA M, NICOLI M, SOATTI G, et al. Augmenting vehicle localization by cooperative sensing of the driving environment: insight on data association in urban traffic scenarios. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(4): 1646–1663.
- [19] CHO S Y. Non-linear FIR smoothing filter for systems with a modelling error and its application to the DR/GPS integrated navigation. *Radar, Sonar & Navigation, IET*, 2018, 12(8): 882–888.
- [20] LI W, JIA Y M, DU J P. TOA-based cooperative localization for mobile stations with NLOS mitigation. *Journal of the Franklin Institute-Engineering and Applied Mathematics*, 2016, 353(6): 1297–1312.
- [21] JULIER S J, UHLMANN J K, DURRANT-WHYTE H F. A new approach for filtering nonlinear systems. *Proceedings of 1995 American Control Conference*. Seattle, Washington, USA, 1995: 1628–1632.
- [22] WANG Y, QIU Z J, QU X M. An improved unscented Kalman filter for discrete nonlinear systems with random parameters. *Discrete Dynamics in Nature and Society*, 2017, 2(26): 1–10.
- [23] QI Y, KOBAYASHI H, SUDA H. On time-of-arrival positioning in a multi-path environment. *IEEE Transactions on Vehicular Technology*, 2006, 55(5): 1516–1526.

### 作者简介:

**谯小康** 硕士研究生, 目前研究方向为信息融合、车辆定位与跟踪, E-mail: 508775470@qq.com;

**屈小媚** 教授, 研究生导师, 目前研究方向为信息融合、目标定位与跟踪, E-mail: Maths.girl@163.com.