

基于改进交互式多模型算法的车辆高精度定位

戴玉峰¹, 苏圣超^{2†}, 崔文霞¹, 汪义旺³

(1. 上海工程技术大学 数理与统计学院, 上海 201620; 2. 上海工程技术大学 创新创业学院, 上海 201620;

3. 苏州市智慧能源技术重点实验室, 江苏 苏州 215104)

摘要: 针对传统交互式多模型算法在车辆运动过程中模型匹配不及时、定位精度较低的问题, 本文提出一种结合改进交互式多模型与容积卡尔曼滤波的算法, 以改善车辆定位效果. 首先, 将惯性测量单元和路侧单元的观测结果融合为量测信息; 然后, 设计一种自适应转弯模型, 应对角速度非固定时单一匀速转弯模型无法有效定位车辆的情况; 进一步考虑模型非线性、状态向量维度较高的特点, 采用容积卡尔曼滤波估计车辆状态; 最后, 提出改进的交互式多模型算法, 通过二次交互优化模型概率. 仿真实验表明, 本文所提算法可以有效提高模型切换速度和车辆定位的准确性与稳定性, 其定位误差相比传统交互式多模型算法降低了 8.6%.

关键词: 车辆定位; 交互式多模型; 卡尔曼滤波; 状态估计

引用格式: 戴玉峰, 苏圣超, 崔文霞, 等. 基于改进交互式多模型算法的车辆高精度定位. 控制理论与应用, 2025, 42(3): 590–600

DOI: 10.7641/CTA.2024.30583

High-precision vehicle positioning based on improved interacting multiple model algorithm

DAI Yu-feng¹, SU Sheng-chao^{2†}, CUI Wen-xia¹, WANG Yi-wang³

(1. School of Mathematics, Physics and Statistics, Shanghai University of Engineering Science, Shanghai 201620, China;

2. School of Innovation and Entrepreneurship, Shanghai University of Engineering Science, Shanghai 201620, China;

3. Suzhou Key Laboratory of Smart Energy Technology, Suzhou Jiangsu 215104, China)

Abstract: In response to the problem of untimely model matching and low positioning accuracy of the traditional interacting multiple model algorithm during vehicle maneuvering, this paper proposes an algorithm that combines the improved interacting multiple model with cubature Kalman filter to improve the performance of vehicle positioning. Firstly, the observations from inertial measurement unit and road side units are fused into the measurement information. Secondly, an adaptive turn model is designed to cope with the situation that a single constant turn model cannot effectively locate the vehicle when the angular velocity is not fixed. Then, the vehicle state is estimated by cubature Kalman filter, due to the nonlinearity of the model and the high dimensionality of the state vector. Finally, an improved interacting multi model algorithm is proposed to optimize the model probability through twice interactions. The simulation experiments show that the algorithm proposed in this paper can effectively improve the model switching speed, as well as the accuracy and stability of vehicle positioning, and its positioning error is reduced by 8.6% compared with the traditional interacting multiple model algorithm.

Key words: vehicle positioning; interacting multiple model; Kalman filters; state estimation

Citation: DAI Yufeng, SU Shengchao, CUI Wenxia, et al. High-precision vehicle positioning based on improved interacting multiple model algorithm. *Control Theory & Applications*, 2025, 42(3): 590–600

1 引言

智能网联汽车技术在维护交通安全、缓解道路拥堵和降低能源消耗等方面发挥了巨大的作用^[1–3]. 作

为智能网联汽车关键技术之一, 车辆高精度定位是实现智能驾驶的前提条件^[4]. 如今, 智能驾驶技术不断发展, 对车辆定位的准确性、稳定性与实时性提出了

收稿日期: 2023–08–28; 录用日期: 2024–05–30.

†通信作者. E-mail: jnssc@sues.edu.cn; Tel.: +86 21-67791023.

本文责任编辑: 侯忠生.

国家自然科学基金项目(61603241), 江苏高校“青蓝工程”(苏教师函[2023]27号), 苏州市科技计划项目(SZS2022015), 苏州市智慧能源技术重点实验室开放课题基金(SLKSET2308)资助.

Supported by the National Natural Science Foundation of China (61603241), the Jiangsu Provincial Universities "Qing-Lan Project", the Science and Technology Planning Project of Suzhou City (SZS2022015) and the Open Project Fund of Suzhou Key Laboratory of Smart Energy Technology (SLKSET2308).

更高的要求^[5].

目前, 全球导航卫星系统(global navigation satellite system, GNSS)已经广泛应用于车辆导航、地图定位等服务, 如北斗导航卫星系统、全球定位系统. 然而, 由于城市峡谷、立交、隧道等场景的存在, 以及多路径效应的影响, GNSS定位的信号强度和连续性难以保证^[6]. 惯性导航系统(inertial navigation system, INS)通过惯性测量单元(inertial measurement unit, IMU)高频率地提供相对定位信息完成航位推算, 但随着时间推移会产生累积误差, 无法保持车辆高精度定位^[7]. 将GNSS和INS互补的GNSS/INS紧耦合导航算法可以保证车辆定位的连续性, 倘若GNSS信号中断时间过长, 未能及时校准INS, 将导致算法失效. 随着通信技术的发展, 采用专用短程通信(dedicated short range communication, DSRC)^[8]技术可以实现车辆与万物通信(vehicle to everything, V2X). 通过无线通信设备测量车辆与多个路边基站之间或者车辆与多个辅助车辆之间的相对位置信息, 如信号到达角度^[9]、到达时间^[10]、到达时间差^[11]以及接收信号强度^[12]等, 可间接实现车辆定位. 此类方法需要综合考虑路网特征, 在保证信号覆盖率的同时降低基建成本. 基于激光雷达等多种传感器的即时定位与地图构建(simultaneous localization and mapping, SLAM)技术在特征丰富的场景下, 能够获得较高的定位精度, 但在遭遇雪、雾等恶劣天气情况时, 其定位性能将会降低^[13].

为实现车辆精准定位、鲁棒定位, 基于V2X无线通信系统^[14], 融合路侧单元(road side unit, RSU)、IMU、车载GNSS、雷达、相机等多种传感器观测信息的协同定位方法引起了众多学者的关注. 文献[15]提出了一种紧耦合GNSS、INS和激光雷达的协同定位方法, 并设计了激光雷达滑动窗口平面特征跟踪算法, 相比传统的GNSS/INS组合导航定位, 在GNSS弱信号的城市环境中, 目标车辆的定位精度有所提高. 文献[16]采用GNSS/INS刷新SLAM, 解决传统SLAM漂移和发散的问题, 在扩展卡尔曼滤波(extended Kalman filter, EKF)预测更新之前对不同测量结果进行交叉验证, 以确保数据融合的可靠性, 在GNSS信号微弱和缺失的情况下实现了车辆定位. EKF通过泰勒级数展开的方法舍去非线性系统的高阶项, 获得一阶精度线性近似结果, 当非线性度较高时, 线性化误差将严重影响滤波精度, 甚至导致滤波发散^[17]. 文献[18]提出了一种视觉与单RSU辅助的车辆定位方法, 通过误差状态卡尔曼滤波算法融合GNSS, IMU, RSU和相机的观测信息完成车辆状态估计, 降低了车辆的定位误差. 无迹卡尔曼滤波(unscented Kalman filter, UKF)通过确定性采样点描述非线性函数的概率分布, 在强非线性系统中滤波效果通常会优于EKF算法^[19]. 文献[20]通过UKF算法修正非线性系统误差, 以估计车辆

的位置姿态, 相较传统组合导航算法具有更高的估计精度. 文献[21]在GNSS和车辆自身航位推算的基础上, 通过V2X实时通信, 测量车辆之间相对距离, 提出了一种基于改进UKF的协同定位算法, 其定位精度会明显优于仅采用GNSS和航位推算独立定位. 然而, UKF算法需要使用权值为负的采样点, 无法保证协方差的正定性. 在文献[22]中提出了一种结合GNSS和DSRC的车辆定位方法, 并将容积卡尔曼滤波(cubature Kalman filter, CKF)作为滤波算法, 使用Huber M估计技术改善滤波效果, 采用自适应调整策略扩大其特性覆盖范围, 在高维系统中仍能保证滤波效果, 具有较强的鲁棒性和自适应能力, 但未考虑车辆运动模型的影响.

需要说明的是, 除根据动态特性选取合适的滤波算法可以获得更好的车辆定位效果, 采用与车辆机动形式相匹配的运动模型同样有助于提高车辆定位精度. 常见的运动模型包括匀速(constant velocity, CV)、匀加速(constant acceleration, CA)、匀速转弯(constant turn, CT)、Singer、“当前”统计模型等^[23]. 机动车辆的实际运动形式复杂多变, 单一模型滤波算法往往难以准确估计其运动状态. 故交互式多模型(interacting multiple model, IMM)算法^[24]成为研究单车多状态运动的热点. 文献[25]通过IMM算法设计了结合车辆横向速度运动学和动力学特性的滤波器, 并验证了所提方法在估计车辆侧滑角度方面的优越性. 文献[26]提出了一种采用IMM原理融合标准CKF、自适应CKF和鲁棒CKF的算法, 可以抑制运动模型和量测模型误差的干扰, 提高了GNSS/INS紧耦合定位的适应性和鲁棒性. 文献[27]设计了融合运动状态自适应IMM卡尔曼滤波和多基站到达方向的车辆位置实时估计算法, 取得了更精确的位置估计结果. 文献[28]提出了一种基于IMM算法的新模型交互方法, 当模型状态向量维数不一致时, 先混合常见一致的状态, 再根据模型概率将原始状态和混合状态加权得到最终估计结果, 避免扩充状态空间, 降低了模型混合的复杂性, 相比于单模型和IMM滤波算法, 所提算法在车辆状态估计方面拥有更好的性能, 然而, 此算法未考虑运动模型的准确性与适配性.

综上所述, 本文从运动模型和滤波算法两个方面考虑, 采用结合二次交互式多模型(twice interacting multiple model, 2IMM)与CKF的2IMM-CKF算法, 并融合IMU和RSU观测所得目标车辆信息, 进行车辆高精度定位. 针对角速度非固定情形下单个CT模型无法有效完成目标车辆定位的问题, 设计了一种自适应转弯(adaptive turn, AT)模型, 以匹配此时车辆的机动形式. 采用CKF作为滤波算法, 满足目标车辆状态估计中运动模型、量测模型非线性以及状态向量维度较高的特点. 由于目标车辆在机动过程中运动形式复

杂多变,充分考虑运动模型的准确性与适配性,提出改进的2IMM算法,以获得更好的定位效果。

2 车辆定位模型

本文架构下的车辆定位模型如图1所示. 由于车辆在短程行驶过程中竖直方向变动较小,仅考虑水平二维平面内的位置和姿态. 车联网环境下,每个RSU均可通过其配备的无线通信设备测量目标车辆与之相对距离和角度. 通过V2X无线通信系统,当终端发起定位请求时,通过边缘计算技术^[29],将车载IMU和多个RSU的测量信息发送至附近边缘服务器完成计算任务,服务器再将定位结果发送回终端. 使用边缘服务器处理IMU和RSU的测量信息,可以提高数据处理能力,满足车辆定位实时性的需求. 通过均匀部署于路侧、配备多输入多输出阵列的RSU测量车辆与路边基站之间的相对距离和角度,通过具备陀螺仪等传感器的IMU测得车辆的角速度等状态信息,结合基站绝对位置和车辆状态信息,采用本文所提算法进行车辆状态估计. 为减小各种干扰的影响,获得更稳定的车辆定位结果,本方案采用附近4个RSU的测量信息估计目标车辆状态,并对估计结果取均值。

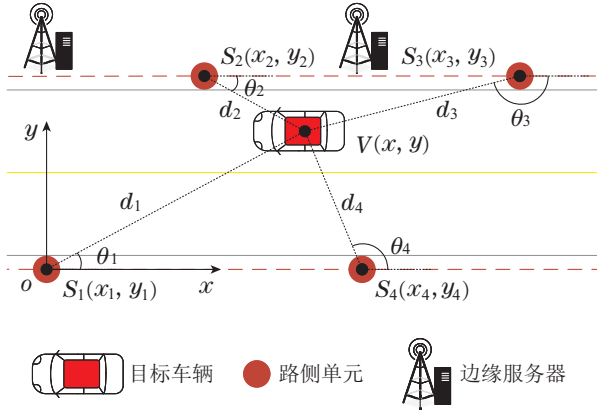


图1 车辆定位模型

Fig. 1 Model for vehicle positioning

记 $\mathbf{X}_k = [x_p \ x_v \ x_a \ y_p \ y_v \ y_a \ \phi \ \omega]^T$ 为目标车辆在 k 时刻的状态向量, 其中: x_p, x_v, x_a 和 y_p, y_v, y_a 分别表示车辆在 x 轴和 y 轴方向位置、速度以及加速度的分量, 航向角 ϕ 表示车辆的质心速度与 x 轴正方向的夹角, ω 表示车辆的转弯角速度. 车辆的离散时间状态方程为

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}) + \mathbf{W}_{k-1}^M, \quad (1)$$

式中: $k-1$ 时刻车辆作 M 运动的过程噪声 \mathbf{W}_{k-1}^M 为零均值高斯白噪声, 其协方差为 \mathbf{Q}_{k-1} ; $f(\mathbf{X}_{k-1})$ 表示关于 \mathbf{X}_{k-1} 的动态过程函数, 其表达式为

$$f(\mathbf{X}_{k-1}) = \mathbf{A}_{k, k-1}^M \mathbf{X}_{k-1}, \quad (2)$$

式中 $\mathbf{A}_{k, k-1}^M$ 为 $k-1$ 时刻到 k 时刻 M 运动模型下车辆

的状态转移矩阵. 车辆的量测方程为

$$\mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{V}_k, \quad (3)$$

式中: \mathbf{Z}_k 表示 k 时刻车辆的量测向量; 车辆的量测噪声 \mathbf{V}_k 为零均值高斯白噪声, 其协方差为 \mathbf{R}_k ; $h(\mathbf{X}_k)$ 表示关于 \mathbf{X}_k 的量测过程非线性函数, 其表达式为

$$h(\mathbf{X}_k) = \begin{bmatrix} \sqrt{(x_p - x_i)^2 + (y_p - y_i)^2} \\ \tan^{-1}\left(\frac{y_p - y_i}{x_p - x_i}\right) \\ \frac{x_v y_a - x_a y_v}{x_v^2 + y_v^2} \end{bmatrix}, \quad (4)$$

式中: 列向量的3个元素分别为RSU所测车辆与路边基站的相对距离和角度, 以及具备陀螺仪的IMU所测车辆的角速度; x_i 和 y_i 为基站 i 的横、纵坐标。

3 车辆运动模型

在机动过程中, 车辆的实际运动形式复杂多变, 单一运动模型往往难以全面、准确地描述其状态, 需要建立多个运动模型以匹配其不同的机动形式. CV, CA, CT, Singer 运动模型的建模过程参见文献[17]. 当车辆转弯角速度不固定时, 单个CT模型难以估计其运动状态. 需要将多个不同角速度的CT模型进行交互, 覆盖车辆在角速度非固定时的运动状态. 若模型切换不及时, 难以提高估计效果, 且模型集过大会增加计算量. 所提AT模型将车辆转弯角速度作为状态向量的一个分量进行估计, 以适应车辆在变道、超车、转弯、调头等角速度非固定情形下的运动状态, 实现角速度自适应. 将角速度 ω 建模为一阶马尔可夫过程, 具有自相关量 $L_\omega(t, t + \tau)$, 其连续时间表达式为

$$L_\omega(t, t + \tau) = E[\omega(t + \tau)\omega(t)] = \eta^2 \exp(-\beta |\tau|), \quad (5)$$

式中: η 为角速度瞬时变化量, 机动频率 β 取 $\frac{1}{\tau_\omega}$, τ_ω 为机动时间常数. 当采样周期为 T 时, 角速度 ω_k 的离散时间方程为

$$\omega_k = \exp(-\beta T)\omega_{k-1} + W_k^\omega, \quad (6)$$

式中 W_k^ω 表示方差为 $\eta^2[1 - \exp(-2\beta T)]$ 的零均值高斯白噪声. 车辆的离散时间状态方程如式(1)所示, 此时为非线性方程, 状态转移矩阵 $\mathbf{A}_{k, k-1}^{\text{AT}}$ 为

$$\begin{cases} \mathbf{A}_{k, k-1}^{\text{AT}} = \text{diag}\{\mathbf{F}_{k, k-1}^{\text{CT}}, \mathbf{F}_{k, k-1}^\omega\}, \\ \mathbf{F}_{k, k-1}^\omega = \begin{bmatrix} 1 & \frac{1 - \exp(-\beta T)}{\beta} \\ 0 & \exp(-\beta T) \end{bmatrix}. \end{cases} \quad (7)$$

过程噪声 \mathbf{W}_k^{AT} 的协方差矩阵 \mathbf{P}^{AT} 为

$$P^{AT} = \text{diag}\{Q^{CT}, Q^\omega\}, \quad (8)$$

式中协方差矩阵块 Q^ω 的表达式为

$$\begin{cases} Q^\omega = 2\beta\eta^2 \begin{bmatrix} q_{11} & q_{12} \\ q_{21} & q_{22} \end{bmatrix}, \\ q_{11} = \frac{2\beta T - 3 + 4\exp(-\beta T) - \exp(-2\beta T)}{2\beta^3}, \\ q_{12} = q_{21} = \frac{1 - 2\exp(-\beta T) + \exp(-2\beta T)}{2\beta^2}, \\ q_{22} = \frac{1 - \exp(-2\beta T)}{2\beta}. \end{cases} \quad (9)$$

4 滤波算法

IMM算法对所有滤波器的状态估计值进行加权求和, 获得最终状态估计结果, 即通过调整权值对不同运动模型下的滤波输出进行混合, 而非在每一时刻选择合适的单一模型进行状态估计. 因此, 运动模型的准确性和模型切换的及时性对估计结果影响较大. 相比于其他强机动目标, 车辆在运动过程中以匀速直线和转弯为主, 在变道、超车等情形下运动模型切换频

繁. 针对车辆运动的特点, 所提2IMM算法根据运动模型的准确性与适配性, 将模型集合分为优先集和非优先集. 在每次交互过程中, 先对优先集运动模型下的滤波结果进行交互, 再将首次交互的结果与非优先集运动模型下的滤波结果进行第2次交互, 从而获得最终估计结果.

为提高车辆定位精度, 本文采用CKF算法完成子滤波器的设计. 考虑到各个运动模型实际使用的状态分量的数量不完全一致, 通过0元素补齐状态向量的方法在EKF算法中可以解决这一问题. 但是, 此方法在CKF算法中将导致低维模型过程噪声方差奇异, 进一步造成滤波估计协方差矩阵奇异, 从而无法分解矩阵获得采样点^[30]. 为此, 在每个子滤波器的滤波过程中, 仅针对该运动模型实际使用的状态分量进行滤波更新. 在每次交互过程中, 根据模型概率仅混合各个运动模型一致使用的状态分量, 同时保持其余状态分量不变.

假设车辆共有 N 种运动模型, 将其中 n 种模型组成优先集, $N \geq 3, 2 \leq n < N$, 则所提2IMM算法流程图如图2所示.

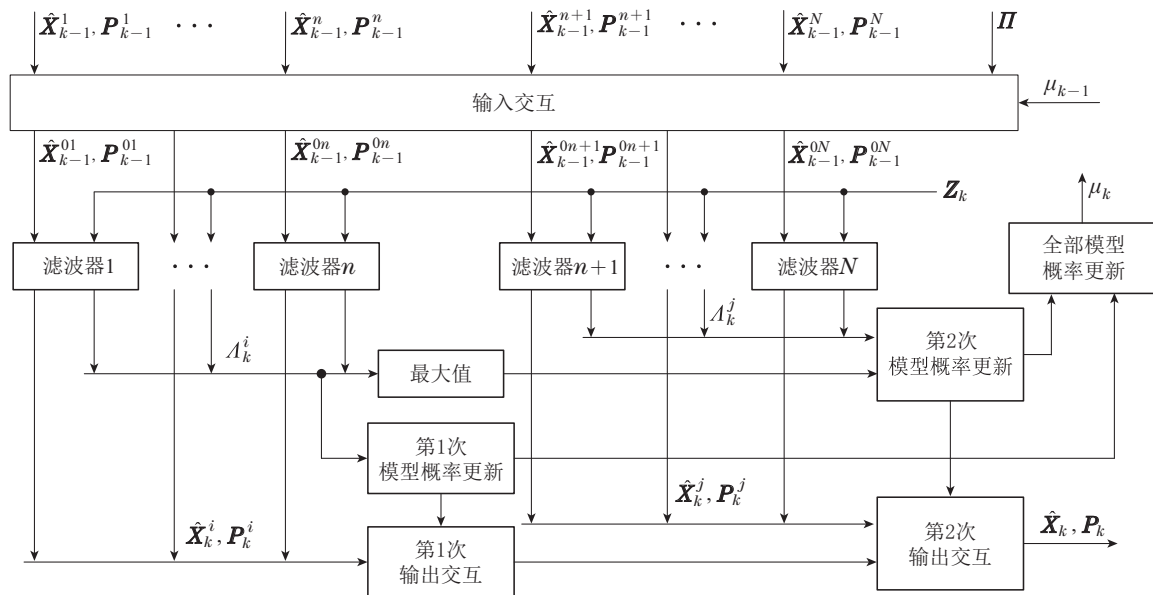


图2 2IMM算法框图

Fig. 2 Block diagram of 2IMM algorithm

模型之间的切换转移服从马尔可夫状态转移概率矩阵 Π , 即

$$\Pi = \begin{bmatrix} \pi_{1,1} & \cdots & \pi_{N,1} \\ \vdots & & \vdots \\ \pi_{1,N} & \cdots & \pi_{N,N} \end{bmatrix}, \quad (10)$$

式中: $i, j = 1, 2, \dots, N, \pi_{j,i}$ 为模型 i 转移到模型 j 的概率, 任意 $i \in \{1, 2, \dots, N\}$ 均满足 $\sum_{j=1}^N \pi_{j,i} = 1$. 若已

经得到 $k-1$ 时刻所有滤波器估计的目标状态向量和协方差矩阵, 以及各个模型的概率和状态转移概率矩阵, 则在一个采样周期内2IMM-CKF算法流程如下:

步骤1 输入交互.

记 $k-1$ 时刻滤波器 i 估计的目标状态向量为 \hat{X}_{k-1}^i , 对应的协方差为 P_{k-1}^i , 模型概率为 μ_{k-1}^i , 经过运动状态转移后, $k-1$ 时刻目标处于模型 j 的概率 ρ_{k-1}^j 可通过状态转移概率矩阵 Π 求得, 并将各模型的预测概率

归一化为常数,即

$$\rho_{k-1}^j = \sum_{i=1}^N \pi_{j,i} \mu_{k-1}^i. \quad (11)$$

$k-1$ 时刻模型 i 转移到模型 j 的条件概率 $\mu_{k-1}^{j,i}$ 为

$$\mu_{k-1}^{j,i} = \frac{(\pi_{j,i} \mu_{k-1}^i)}{\rho_{k-1}^j}. \quad (12)$$

将 $k-1$ 时刻全部模型的估计结果进行交互后,目标的状态向量 $\hat{\mathbf{X}}_{k-1}^{0j}$ 及其协方差矩阵 \mathbf{P}_{k-1}^{0j} 分别为

$$\hat{\mathbf{X}}_{k-1}^{0j} = \sum_{i=1}^N \hat{\mathbf{X}}_{k-1}^i \mu_{k-1}^{j,i}, \quad (13)$$

$$\mathbf{P}_{k-1}^{0j} = \sum_{i=1}^N [(\hat{\mathbf{X}}_{k-1}^i - \hat{\mathbf{X}}_{k-1}^{0j})(\hat{\mathbf{X}}_{k-1}^i - \hat{\mathbf{X}}_{k-1}^{0j})^T + \mathbf{P}_{k-1}^i] \mu_{k-1}^{j,i}. \quad (14)$$

步骤2 并行滤波.

将所有 $\hat{\mathbf{X}}_{k-1}^{0j}$ 和 \mathbf{P}_{k-1}^{0j} 作为输入,并结合目标量测向量 \mathbf{Z}_k ,采用CKF算法对各个运动模型同时进行滤波估计,获得 k 时刻子滤波器估计的目标状态向量 $\hat{\mathbf{X}}_k^j$ 及其协方差矩阵 \mathbf{P}_k^j ,量测预测向量 $\hat{\mathbf{Z}}_{k,k-1}^j$ 和新息协方差矩阵 \mathbf{S}_k^j ,以及量测向量与量测预测向量之间的偏差 ξ_k^j .以运动模型 i 为例,滤波过程如下:

1) 产生容积点.

$$\begin{cases} \mathbf{s}_r = \sqrt{m}[\mathbf{I}, -\mathbf{I}]_r, \\ w_r = \frac{1}{2m}, \end{cases} \quad (15)$$

根据式(15)产生容积点集 $\{\mathbf{s}_r, w_r\}$,其中: m 表示状态向量维数, $r=1, 2, \dots, 2m$, \mathbf{I} 表示 m 维单位矩阵, $[\mathbf{I}, -\mathbf{I}]_r$ 为矩阵 $[\mathbf{I}, -\mathbf{I}]$ 的第 r 列, w_r 为对应容积点的权值.将 $\{\mathbf{s}_r, w_r\}$ 数值化计算积分可以完成高斯分布下的非线性滤波.通过 $k-1$ 时刻的交互结果 $\hat{\mathbf{X}}_{k-1}^{0i}$ 及其协方差 \mathbf{P}_{k-1}^{0i} ,计算其第 r 个容积点 χ_{k-1}^r ,即

$$\begin{cases} \chi_{k-1}^r = \hat{\mathbf{X}}_{k-1}^{0i} + \tilde{\mathbf{P}}_{k-1} \mathbf{s}_r, \\ \mathbf{P}_{k-1}^{0i} = \tilde{\mathbf{P}}_{k-1} \tilde{\mathbf{P}}_{k-1}^T, \end{cases} \quad (16)$$

式中 $\tilde{\mathbf{P}}_{k-1}$ 由 \mathbf{P}_{k-1}^{0i} 经过Cholesky分解得到.

2) 更新容积点.

根据式(2)动态过程函数更新容积点,进行容积点非线性变换,得到各个容积点的预测值,即

$$\hat{\chi}_{k,k-1}^r = f(\chi_{k-1}^r). \quad (17)$$

3) 预测状态及其协方差.

通过 $2m$ 个容积点的预测值计算 k 时刻状态预测向量 $\hat{\mathbf{X}}_{k,k-1}^i$ 及其协方差矩阵 $\mathbf{P}_{k,k-1}^i$,即

$$\hat{\mathbf{X}}_{k,k-1}^i = \sum_{r=1}^{2m} \hat{\chi}_{k,k-1}^r w_r, \quad (18)$$

$$\mathbf{P}_{k,k-1}^i = \sum_{r=1}^{2m} [(\hat{\chi}_{k,k-1}^r - \hat{\mathbf{X}}_{k,k-1}^i)(\hat{\chi}_{k,k-1}^r - \hat{\mathbf{X}}_{k,k-1}^i)^T + \mathbf{P}_{k-1}^i] w_r.$$

$$\hat{\mathbf{X}}_{k,k-1}^i)^T w_r] + \mathbf{Q}_{k-1}. \quad (19)$$

4) 产生量测容积点.

根据 k 时刻状态预测向量 $\hat{\mathbf{X}}_{k,k-1}^i$ 及其协方差矩阵 $\mathbf{P}_{k,k-1}^i$,计算其第 r 个量测容积点 $\chi_{k,k-1}^r$,即

$$\begin{cases} \chi_{k,k-1}^r = \hat{\mathbf{X}}_{k,k-1}^i + \tilde{\mathbf{P}}_{k,k-1} \mathbf{s}_r, \\ \mathbf{P}_{k,k-1}^i = \tilde{\mathbf{P}}_{k,k-1} \tilde{\mathbf{P}}_{k,k-1}^T, \end{cases} \quad (20)$$

式中 $\tilde{\mathbf{P}}_{k,k-1}$ 由 $\mathbf{P}_{k,k-1}^i$ 经过Cholesky分解得到.

5) 更新量测容积点.

根据式(4)量测过程函数更新量测容积点,通过非线性变换得到各个量测容积点在 k 时刻的预测值,即

$$\hat{\mathbf{Z}}_{k,k-1}^r = h(\chi_{k,k-1}^r). \quad (21)$$

6) 预测量测和新息协方差.

通过 $2m$ 个量测容积点的预测值计算 k 时刻量测预测向量 $\hat{\mathbf{Z}}_{k,k-1}^i$ 和新息协方差矩阵 \mathbf{S}_k^i ,即

$$\hat{\mathbf{Z}}_{k,k-1}^i = \sum_{r=1}^{2m} \hat{\mathbf{Z}}_{k,k-1}^r w_r, \quad (22)$$

$$\begin{aligned} \mathbf{S}_k^i = \sum_{r=1}^{2m} [(\hat{\mathbf{Z}}_{k,k-1}^r - \hat{\mathbf{Z}}_{k,k-1}^i)(\hat{\mathbf{Z}}_{k,k-1}^r - \hat{\mathbf{Z}}_{k,k-1}^i)^T \\ + \mathbf{P}_{k,k-1}^i] w_r] + \mathbf{R}_k. \end{aligned} \quad (23)$$

7) 计算增益矩阵.

状态预测向量 $\hat{\mathbf{X}}_{k,k-1}^i$ 与量测预测向量 $\hat{\mathbf{Z}}_{k,k-1}^i$ 之间的互协方差 \mathbf{C}_k^i 为

$$\begin{aligned} \mathbf{C}_k^i = \sum_{r=1}^{2m} [(\hat{\chi}_{k,k-1}^r - \hat{\mathbf{X}}_{k,k-1}^i)(\hat{\mathbf{Z}}_{k,k-1}^r - \hat{\mathbf{Z}}_{k,k-1}^i)^T \\ + \mathbf{P}_{k,k-1}^i] w_r, \end{aligned} \quad (24)$$

则滤波增益矩阵 \mathbf{K}_k^i 为

$$\mathbf{K}_k^i = \mathbf{C}_k^i (\mathbf{S}_k^i)^{-1}. \quad (25)$$

8) 估计状态及其协方差.

记量测向量 \mathbf{Z}_k 与量测预测向量 $\hat{\mathbf{Z}}_{k,k-1}^i$ 之间的偏差向量为 ξ_k^i ,即

$$\xi_k^i = \mathbf{Z}_k - \hat{\mathbf{Z}}_{k,k-1}^i, \quad (26)$$

则 k 时刻后验状态向量估计 $\hat{\mathbf{X}}_k^i$ 及其协方差 \mathbf{P}_k^i 分别为

$$\hat{\mathbf{X}}_k^i = \hat{\mathbf{X}}_{k,k-1}^i + \mathbf{K}_k^i \xi_k^i, \quad (27)$$

$$\mathbf{P}_k^i = \mathbf{P}_{k,k-1}^i - \mathbf{K}_k^i \mathbf{S}_k^i (\mathbf{K}_k^i)^T. \quad (28)$$

步骤3 第1次模型概率更新.

$$A_k^i = \frac{\exp[-(\xi_k^i)^T (\mathbf{S}_k^i)^{-1} \xi_k^i / 2]}{\sqrt{(2\pi)^D |\mathbf{S}_k^i|}}, \quad (29)$$

根据式(29)计算模型 i 的似然函数值,其中: D 为量测向量维数, $i=1, 2, \dots, n$.似然函数包含当前量测信息,其函数值的大小反映了模型 i 与目标车辆当前实际

运动状态的匹配程度. 似然函数值 A_k^i 越大, 表明模型 i 与车辆实际状态越匹配, 反之亦然. 通过似然函数值更新优先集内 n 个模型的概率, 则模型 i 的概率为

$$\mu_k^i = \frac{A_k^i \rho_{k-1}^i}{\sum_{l=1}^n A_k^l \rho_{k-1}^l}. \quad (30)$$

步骤4 第1次输出交互.

基于优先集模型的概率, 对 n 个滤波器的估计结果进行加权合并, 得到第1次交互输出状态向量 \hat{X}_k^0 及其协方差矩阵 P_k^0 , 即

$$\hat{X}_k^0 = \sum_{i=1}^n \hat{X}_k^i \mu_k^i, \quad (31)$$

$$P_k^0 = \sum_{i=1}^n [P_k^i + (\hat{X}_k^i - \hat{X}_k^0) \times (\hat{X}_k^i - \hat{X}_k^0)^T] \mu_k^i. \quad (32)$$

步骤5 第2次模型概率更新.

在通过似然函数值更新模型概率时, 若此模型的函数值相较于其他模型的函数值更大, 则更新后此模型的概率更高, 反之, 则概率变低. 为使优先集模型的交互结果在第2次交互输出中占有更高的比重, 选择优先集模型中似然函数最大值进行第2次模型概率更新. 记优先集模型中最大的似然函数值为 A_k^0 , 即

$$A_k^0 = \max \{A_k^1, A_k^2, \dots, A_k^n\}, \quad (33)$$

通过式(29)计算非优先集模型 i 的似然函数值 A_k^i , 此时 $i = n+1, \dots, N$. 非优先集模型 i 的概率更新为

$$\mu_k^i = \frac{A_k^i \rho_{k-1}^i}{\sum_{l=1}^n A_k^0 \rho_{k-1}^l + \sum_{l=n+1}^N A_k^l \rho_{k-1}^l}, \quad (34)$$

第1次交互结果的概率 μ_k^0 为

$$\mu_k^0 = \frac{\sum_{i=1}^n A_k^0 \rho_{k-1}^i}{\sum_{l=1}^n A_k^0 \rho_{k-1}^l + \sum_{l=n+1}^N A_k^l \rho_{k-1}^l}. \quad (35)$$

步骤6 第2次输出交互.

将第1次交互结果和非优先集模型的滤波结果进行加权合并, 得到第2次交互输出状态向量 \hat{X}_k 及其协方差矩阵 P_k , 即最终估计结果为

$$\hat{X}_k = \hat{X}_k^0 \mu_k^0 + \sum_{i=n+1}^N \hat{X}_k^i \mu_k^i, \quad (36)$$

$$P_k = [P_k^0 + (\hat{X}_k^0 - \hat{X}_k)(\hat{X}_k^0 - \hat{X}_k)^T] \mu_k^0 + \sum_{i=n+1}^N [P_k^i + (\hat{X}_k^i - \hat{X}_k)(\hat{X}_k^i - \hat{X}_k)^T] \mu_k^i. \quad (37)$$

步骤7 全部模型概率更新.

由于式(30)对优先集模型的概率进行了归一化处理, 导致当前所有模型概率之和大于1, 而 k 时刻所有

模型概率之和应等于1, 故模型概率 μ_k^i 更新为

$$\mu_k^i = \begin{cases} \mu_k^i \mu_k^0, & i = 1, 2, \dots, n, \\ \mu_k^i, & i = n+1, \dots, N. \end{cases} \quad (38)$$

5 仿真实验与结果分析

本文仿真实验均在一台拥有1.80 GHz主频的Intel Core i7-8565U CPU和16.0 GB内存的计算机上完成. 为研究本文所提算法效果, 在MATLAB R2022a中建立车辆运动场景并进行仿真. 实验场景如图3所示, 二维平面中双向四车道每条宽3.75 m, RSU间隔100 m交错部署于道路两侧2 m处, 其通信半径为160 m. 目标车辆从起点(0, 0)处, 以初始速度10 m/s朝 x 轴正方向运动, 即初始状态向量为 $[0 \ 10 \ 0 \ 0 \ 0 \ 0 \ 0]^T$, 其运动过程如表1所示. 不考虑非视距影响, RSU测量目标车辆的距离和角度误差为不相关的零均值高斯白噪声, 其标准差 σ_d , σ_θ 分别设为0.6 m和0.5°, 陀螺仪的量测噪声标准差 σ_ω 设为0.3°/s, 所有传感器的采样周期 T 为0.05 s. 假设各个RSU和陀螺仪在同一时刻的量测噪声均不相关, 且各传感器在不同时刻的量测噪声也不相关.




图3 车辆运动场景

Fig. 3 Scenario of vehicle motion

表1 车辆运动过程

Table 1 Process of vehicle motion

t/s	运动过程
0~4.0	10 m/s匀速直线运动
4.0~8.0	2.5 m/s ² 匀加速直线运动
8.0~12.0	变角速度转至左车道
12.0~14.5	2 m/s ² 匀加速直线运动
14.5~18.5	-5 m/s ² 匀减速直线运动
18.5~22.7	变角速度左转调头
22.7~25.2	-4 m/s ² 匀加速直线运动
25.2~30.0	变角速度转至左车道
30.0~32.0	-5 m/s ² 匀加速直线运动
32.0~35.6	变角速度转至右车道
35.6~38.6	3 m/s ² 匀减速直线运动
38.6~40.0	匀速直线运动

为验证本文所提算法的性能, 采用Monte Carlo仿真方法进行200次独立实验. 对各次仿真实验的算法运行时间求均值, 将单步定位平均运行时间作为实时

性评价指标. 将位置和速度的均方根误差(root mean square error, RMSE)作为定位精度评价指标.

$$\text{RMSE}_{p,x} = \sqrt{\frac{1}{\text{MC}} \sum_{i=1}^{\text{MC}} (x_{p,k} - \hat{x}_{p,k}^i)^2}, \quad (39)$$

$$\text{RMSE}_{\text{pos}} = \sqrt{(\text{RMSE}_{p,x})^2 + (\text{RMSE}_{p,y})^2}, \quad (40)$$

式中: MC为Monte Carlo仿真次数; $x_{p,k}$ 为 k 时刻 x 轴方向的车辆位置真实值; $\hat{x}_{p,k}^i$ 为第 i 次仿真中 k 时刻 x 轴方向的车辆位置估计值; $\text{RMSE}_{p,x}$, $\text{RMSE}_{p,y}$ 分别表示 x 轴, y 轴方向的位置估计均方根误差, 则根据式(40)可以计算总的位置均方根误差 RMSE_{pos} , 类似可得速度均方根误差 RMSE_{vel} .

为保证实验对比的公平性, 在以下仿真实验中, 将CV, CA, CT, AT模型的过程噪声增益均设置为3.5, CT模型的转弯角速度 ω 设置为 $20^\circ/\text{s}$, Singer模型的参数 α , σ 分别设置为0.8和5, AT模型中角速度的参数 β , η 分别设置为0.02和0.17. 在IMM和2IMM算法中, 所选交互模型的参数设置与上述一致, 运动模型概率初始值均设为 $[\frac{1}{3} \quad \frac{1}{3} \quad \frac{1}{3}]$, 状态转移概率矩阵均设为

$$\mathbf{\Pi} = \begin{bmatrix} 0.98 & 0.01 & 0.01 \\ 0.01 & 0.98 & 0.01 \\ 0.01 & 0.01 & 0.98 \end{bmatrix}.$$

5.1 仿真实验1

为验证本文所提量测方案的效果, 在图3所示场景中, 通过与目标车辆最近的若干个RSU测量相对距离和角度, 采用Singer模型和CKF算法设计滤波器, 估计车辆状态, 对估计值取平均得到最终定位结果. 当使用的RSU数量分别为1, 2, 3, 4个时, 经量测转换, 测量均值的位置RMSE如图4所示, 车辆估计状态的位置RMSE如图5所示. 在图3所示场景中, 分别采用AT, CV, CA, CT, Singer模型与CKF算法设计滤波器, 进行目标车辆定位并分析其性能, 各算法估计状态的位置RMSE和速度RMSE如图6-7所示, 位置和速度的平均RMSE、单步定位的平均运行时间如表2所示.




图4 不同RSU数量下的量测误差

Fig. 4 Measurement error with different number of RSUs




图5 不同RSU数量下的估计误差

Fig. 5 Estimation error with different number of RSUs




图6 各算法的位置RMSE

Fig. 6 Position RMSE of each algorithm

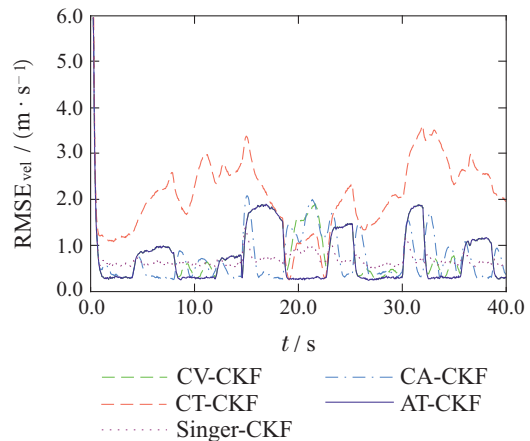


图7 各算法的速度RMSE

Fig. 7 Velocity RMSE of each algorithm

表2 各算法的性能

Table 2 Performance of each algorithm

算法	位置平均 RMSE/m	速度平均 RMSE/(m·s ⁻¹)	平均运行 时间/ms
CV-CKF	0.221 0	0.971 0	0.109 9
CA-CKF	0.211 8	0.804 8	0.113 7
CT-CKF	0.362 5	2.150 3	0.102 8
AT-CKF	0.208 1	0.822 1	0.103 6
Singer-CKF	0.203 6	0.788 2	0.112 0

由图4-5可得, 测量结果均值的位置RMSE和最终估计结果的位置RMSE均随RSU数量的增加而降低, 且降幅不断减小. 继续增加RSU数量, 定位效果提升有限, 更加大了计算量以及能耗. 当RSU数量为1个时, 量测信息较少, 切换RSU时量测信息差异较大, 导致定位精度低且波动剧烈. 随着RSU数量的增加, 量测信息增多, 抗干扰能力提高, 因此定位精度和稳定性均明显提高. 综合考虑定位效果以及成本能耗, 本文采用4个RSU的量测方案较好.

由图6-7可得, CV模型在车辆作匀速直线运动时定位效果较好, 运动过程如0.0~4.0 s, 38.6~40.0 s; 在角速度变化不大的转弯运动下误差比较小, 运动过程如8.0~12.0 s, 25.2~30.0 s, 32.0~35.6 s; 在匀加(减)速直线运动和角速度变化剧烈的转弯运动下效果比较差, 运动过程如12.0~25.2 s, 30.0~32.0 s, 35.6~38.6 s. CA模型在车辆作匀速、匀加(减)速直线运动和角速度变化不大的转弯运动时, 状态估计精度较高, 运动过程如0.0~8.0s, 12.0~14.5s, 25.2~30.0s, 35.6~40.0 s; 但在角速度变化剧烈的转弯运动下定位效果较差, 当速度变化剧烈时鲁棒性较差, 运动过程如18.5~22.7 s, 14.5 s附近. CT模型先验转弯角速度固定, 仅当车辆作角速度相近的转弯运动时可以短暂地实现有效定位, 如18.5 s和22.7 s附近, 而在其余运动过程中定位误差均迅速增大, 无法有效定位. AT模型在车辆作匀速直线运动和转弯运动时均能获得较好的定位效果, 运动过程如0.0~4.0 s, 8.0~12.0 s, 18.5~22.7 s, 25.2~30.0 s; 但在匀加(减)速直线运动下定位效果较差, 运动过程如14.5~18.5 s, 22.7~25.2 s, 30.0~32.0 s. Singer模型鲁棒性较好, 定位精度波动较小, 在速度变化剧烈时仍能保持较好的定位效果, 如14.5 s和22.7 s附近; 但在车辆的各个运动过程中相比于其他运动模型, 定位效果并不理想. 由表2可得, 各模型算法的平均运行时间相近, 而CT模型估计结果的平均RMSE最大, CV模型次之, CA, AT与Singer模型的定位误差相近. 以位置平均RMSE为例, 所提AT模型定位误差比CT模型降低了42.6%, 比CV模型降低了5.8%, 与CA, Singer模型相差不足2.5%.

由实验结果可知, 所提AT模型相比于其他模型, 在车辆进行转弯运动时定位精度较高, 且单一运动模型难以满足各种运动形式下的车辆状态估计. 目标车辆附近4个RSU的测量结果经量测转换, 其平均测量值RMSE稳定在0.4 m左右, 相较单个RSU量测误差大大降低, 车辆定位的稳定性也明显提高.

5.2 仿真实验2

仿真实验1验证了本文所提AT模型在车辆进行转弯运动时的定位效果, 以及单一运动模型对目标车辆状态估计的局限性. 基于实验1, 本次仿真实验采用结

合多个运动模型的IMM算法进行车辆定位. 为降低计算量, 避免因模型之间过度竞争导致估计效果变差, 在保证目标车辆所有机动形式尽量覆盖的前提下, 选取运动模型的数量应尽可能少. 当车辆作匀速直线运动时, 可以通过加速度为0的CA模型或者角速度变化微弱的AT模型估计其状态. 因此, IMM-CKF算法交互CA, AT, Singer 3种模型, 并结合CKF算法进行目标车辆定位, 其位置、速度RMSE分别如图8、图9所示, 位置和速度的平均RSME、单步定位的平均运行时间如表3所示.




图8 各算法的位置RMSE

Fig. 8 Position RMSE of each algorithm

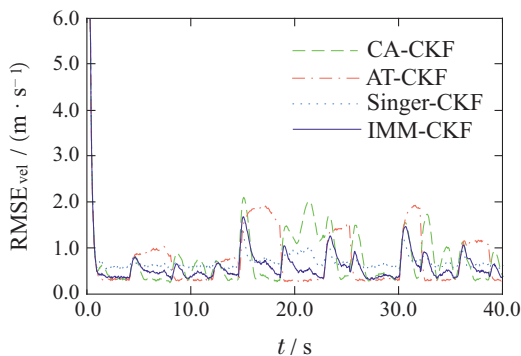


图9 各算法的速度RMSE

Fig. 9 Velocity RMSE of each algorithm

表3 IMM-CKF算法的性能

Table 3 Performance of the IMM-CKF algorithm

算法	位置平均 RMSE/m	速度平均 RMSE/(m·s ⁻¹)	平均运行 时间/ms
IMM-CKF	0.183 2	0.661 4	0.350 0

由图8-9可得, 当目标车辆作匀速直线运动时, IMM-CKF算法与CA, AT模型单独定位精度相近, 具有较好的定位效果; 当车辆作匀加(减)速直线运动时, IMM-CKF算法的定位精度不断与CA模型接近; 当车辆作转弯运动时, IMM-CKF算法与AT模型单独定位精度相近; 当车辆速度变化剧烈时, IMM-CKF算法受

益于Singer模型,鲁棒性明显强于CA, AT模型单独定位,能迅速跟踪并提高定位精度.由表3可得,相比实验1中各模型单独定位车辆, IMM-CKF算法整体定位精度明显提高.以位置平均RMSE为例, IMM-CKF算法的定位误差比CV-CKF降低了17.1%,比CA-CKF降低了13.5%,比CT-CKF降低了49.5%,比AT-CKF降低了12.0%,比Singer-CKF降低了10.0%. IMM-CKF算法引入AT模型,仅交互3种运动模型,其平均运行时间为单一模型的3倍左右,保障了算法的实时性.

5.3 仿真实验3

仿真实验2验证了IMM-CKF算法的定位效果优于单一运动模型.然而,车辆的实际运动形式复杂多变,传统IMM算法下模型概率调整不及时,难以实现高精度车辆定位.为验证本文所提2IMM-CKF算法的效果,本次仿真实验基于实验2,采用CA, AT, Singer 3种运动模型进行二次交互.先将CA, AT模型作为优先集第1次交互,再将交互结果与Singer模型完成第2次交互,得到最终的状态估计结果.2IMM-CKF算法与IMM-CKF, IMM-UKF, IMM-EKF算法的仿真结果如图10-11所示,2IMM-CKF与IMM-CKF算法下各个运动模型的概率变化分别如图12-13所示,各算法的位置和速度的平均RSME、单步定位的平均运行时间如表4所示.

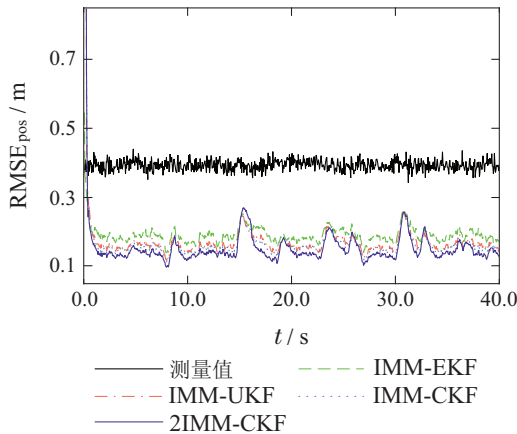


图 10 各算法的位置RMSE

Fig. 10 Position RMSE of each algorithm




图 11 各算法的速度RMSE

Fig. 11 Velocity RMSE of each algorithm




图 12 IMM-CKF算法下的模型概率

Fig. 12 Model probabilities under the IMM-CKF algorithm




图 13 2IMM-CKF算法下的模型概率

Fig. 13 Model probabilities under the 2IMM-CKF algorithm

表 4 各算法的性能

Table 4 Performance of each algorithm

算法	位置平均 RMSE/m	速度平均 RMSE/(m·s ⁻¹)	平均运行 时间/ms
IMM-EKF	0.193 7	0.710 5	0.165 1
IMM-UKF	0.188 0	0.678 1	0.279 2
IMM-CKF	0.183 2	0.661 4	0.350 0
2IMM-CKF	0.167 5	0.622 1	0.345 1

由图10-13可得, IMM-EKF算法的整体定位精度较差. IMM-UKF算法的定位效果比IMM-EKF算法稍好.虽然IMM-CKF算法的滤波精度较高,但在车辆运动形式复杂多样且切换频繁时,匹配模型的概率提升缓慢,严重影响整体定位精度进一步提高.本文所提2IMM-CKF算法既提高了模型切换的速度,又增加了模型匹配的概率,相较于其他算法整体定位精度最高.在车辆速度变化剧烈时,由于上一时刻匹配模型的概率较高,切换至当前匹配模型需要进行概率调整,故所提算法的定位误差会在短暂时间内升高,但很快降低,其平均定位误差仍然保持在较低水平,如表4所示.以位置平均RMSE为例,2IMM-CKF算法的定位误差比IMM-EKF算法降低了13.5%,比IMM-UKF算法降低了10.9%,比IMM-CKF算法降低了8.6%.考虑到目

标车辆在实际运动过程中以匀速直线和变角速度转弯为主, 所提算法将有更好的定位效果。所提算法的平均运行时间虽然比IMM-EKF和IMM-UKF长, 但与IMM-CKF算法相近。这是因为2IMM算法主要针对传统IMM进行结构性改进, 计算量无明显变化。综上分析, 2IMM-CKF算法的车辆定位整体性能最佳。

6 结论

本文融合了IMU和多个RSU观测所得目标车辆信息进行定位, 有力保障了车辆定位的准确性与稳定性。所提AT模型, 在角速度非固定情形下, 实现了车辆转弯机动过程全覆盖, 其位置平均RMSE相比传统CV, CT模型分别降低了5.8%, 42.6%, 在多模型交互过程中, 减少了交互模型的数量, 降低了交互算法的复杂度, 保证了算法的实时性。所提2IMM-CKF算法, 其子滤波器的状态估计效果更好, 运动模型的切换速度更快, 提高了车辆定位的整体性能, 其位置平均RMSE相较于IMM-EKF, IMM-UKF, IMM-CKF算法分别降低了13.5%, 10.9%, 8.6%。

所作研究为未来道路基础设施下车辆高精度定位技术的应用提供了参考方案和理论依据。考虑到实际道路上的运动车辆往往不止一个, 未来将针对多目标车辆协同定位算法开展研究, 并设计多速率数据融合方案处理多目标车辆下的多源信息, 以提高区域内信息利用率和整体定位精度, 保障道路区间安全。

参考文献:

- [1] WANG H F, WANG Y F, ZHAO X M, et al. Lane detection of curving road for structural highway with straight-curve model on vision. *IEEE Transactions on Vehicular Technology*, 2019, 68(6): 5321 – 5330.
- [2] TONGUZ O K, ZHANG R. Harnessing vehicular broadcast communications: DSRC-actuated traffic control. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(2): 509 – 520.
- [3] DONG H X, ZHUANG W C, DING H N, et al. Event-driven energy-efficient driving control in urban traffic for connected electric vehicles. *IEEE Transactions on Transportation Electrification*, 2023, 9(1): 99 – 113.
- [4] GUO Ge, LIU Jiageng, SUN Xiaozheng. Secure robust precise vehicle localization with 5G/GNSS fusion: Advances and prospects. *Control and Decision*, 2023, 38(2): 289 – 303.
(郭戈, 刘佳庚, 孙晓峥. 融合5G/GNSS的车辆高精度鲁棒安全定位: 进展与展望. *控制与决策*, 2023, 38(2): 289 – 303.)
- [5] LU Y Q, MA H J, SMART E, et al. Real-time performance-focused localization techniques for autonomous vehicle: A review. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 6082 – 6100.
- [6] YAN Z, CHEN X Y, TANG X H, et al. Design and performance evaluation of the improved INS-assisted vector tracking for the multipath in urban canyons. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1 – 16.
- [7] ZHANG Q, NIU X J, SHI C. Impact assessment of various IMU error sources on the relative accuracy of the GNSS/INS systems. *IEEE Sensors Journal*, 2020, 20(9): 5026 – 5038.
- [8] MORADI-PARI E, TIAN D, BAHRAMGIRI M, et al. DSRC versus LTE-V2X: Empirical performance analysis of direct vehicular communication technologies. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(5): 4889 – 4903.
- [9] ZHENG Y, SHENG M, LIU J Y, et al. Exploiting AoA estimation accuracy for indoor localization: A weighted AoA-based approach. *IEEE Wireless Communications Letters*, 2019, 8(1): 65 – 68.
- [10] AN X Y, ZHAO S H, CUI X W, et al. Robust vehicle positioning based on multi-epoch and multi-antenna TOAs in harsh environments. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(11): 21074 – 21089.
- [11] WANG T, XIONG H, DING H, et al. TDOA-based joint synchronization and localization algorithm for asynchronous wireless sensor networks. *IEEE Transactions on Communications*, 2020, 68(5): 3107 – 3124.
- [12] ZOU Y B, LIU H P. RSS-based target localization with unknown model parameters and sensor position errors. *IEEE Transactions on Vehicular Technology*, 2021, 70(7): 6969 – 6982.
- [13] SALEEM H, MALEKIAN R, MUNIR H. Neural network-based recent research developments in SLAM for autonomous ground vehicles: A review. *IEEE Sensors Journal*, 2023, 23(13): 13829 – 13858.
- [14] SEHLA K, NGUYEN T M T, PUJOLLE G, et al. Resource allocation modes in C-V2X: From LTE-V2X to 5G-V2X. *IEEE Internet of Things Journal*, 2022, 9(11): 8291 – 8314.
- [15] LI S Y, WANG S W, ZHOU Y X, et al. Tightly coupled integration of GNSS, INS, and LiDAR for vehicle navigation in urban environments. *IEEE Internet of Things Journal*, 2022, 9(24): 24721 – 24735.
- [16] CHIANG K W, TSAI G J, CHU H J, et al. Performance enhancement of INS/GNSS/Refreshed-SLAM integration for acceptable lane-level navigation accuracy. *IEEE Transactions on Vehicular Technology*, 2020, 69(3): 2463 – 2476.
- [17] LIU M Q, LAN J. *Frontier Theory and Application of Target Tracking*. Beijing: Science Press, 2015: 38 – 149.
- [18] SHENG Shuxuan, JING Chongbo, JIANG Chaoyang. Vision and single RSU assisted vehicle positioning method. *Automotive Engineering*, 2022, 44(7): 1009 – 1017, 1026.
(盛树轩, 荆崇波, 蒋朝阳. 视觉与单路侧单元辅助的车辆定位方法. *汽车工程*, 2022, 44(7): 1009 – 1017, 1026.)
- [19] GIANNITRAPANI A, CECCARELLI N, SCORTECCI F, et al. Comparison of EKF and UKF for spacecraft localization via angle measurements. *IEEE Transactions on Aerospace and Electronic Systems*, 2011, 47(1): 75 – 84.
- [20] HU H D, HUANG X L. SINS/CNS/GPS integrated navigation algorithm based on UKF. *Journal of Systems Engineering and Electronics*, 2010, 21(1): 102 – 109.
- [21] QIAO Xiaokang, QU Xiaomei. Vehicle to vehicle-based distributed cooperative sensing positioning for internet of vehicles. *Control Theory & Applications*, 2021, 38(7): 988 – 996.
(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.)
- [22] 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.
- [23] HAN C Z, ZHU H Y, DUAN Z S, et al. *Multi-source Information Fusion*. Second edition. Beijing: Tsinghua University Press, 2010: 139 – 154.
- [24] BLOM H A P, BAR-SHALOM Y. The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE Transactions on Automatic Control*, 1988, 33(8): 780 – 783.
- [25] PARK G. Vehicle sideslip angle estimation based on interacting multiple model Kalman filter using low-cost sensor fusion. *IEEE Transactions on Vehicular Technology*, 2022, 71(6): 6088 – 6099.

- [26] GAO B B, HU G G, ZHONG Y M, et al. Cubature Kalman filter with both adaptability and robustness for tightly-coupled GNSS/INS integration. *IEEE Sensors Journal*, 2021, 21(13): 14997 – 15011.
- [27] WANG Faan, YIN Guodong, ZHUANG Weichao, et al. IMMKF-DOA auxiliary vehicle cooperative localization algorithm based on multi-base station. *Journal of Mechanical Engineering*, 2023, 59(4): 125 – 134.
(王法安, 殷国栋, 庄伟超, 等. 基于多基站IMMKF-DOA辅助车辆协同定位算法研究. *机械工程学报*, 2023, 59(4): 125 – 134.)
- [28] ZUBACA J, STOLZ M, SEEBER R, et al. Innovative interaction approach in IMM filtering for vehicle motion models with unequal states dimension. *IEEE Transactions on Vehicular Technology*, 2022, 71(4): 3579 – 3594.
- [29] MOUBAYED A, SHAMI A, HEIDARI P, et al. Edge-enabled V2X service placement for intelligent transportation systems. *IEEE Transactions on Mobile Computing*, 2021, 20(4): 1380 – 1392.
- [30] FARRELL W J. Interacting multiple model filter for tactical ballistic missile tracking. *IEEE Transactions on Aerospace and Electronic Systems*, 2008, 44(2): 418 – 426.

作者简介:

戴玉峰 硕士研究生, 目前研究方向为车辆定位与跟踪、信息融合, E-mail: daiyvfeng@163.com;

苏圣超 副教授, 目前研究方向为智能驾驶与控制、边缘计算车联网计算任务卸载与调度等, E-mail: jnssc@sues.edu.cn;

崔文霞 讲师, 目前研究方向为切换复杂网络的同步与控制等, E-mail: cuiwx423@163.com;

汪义旺 教授, 目前研究方向为智能控制、新能源技术等, E-mail: wyiwang@163.com.