

DOI: 10.19650/j.cnki.cjsi.J2210040

遮挡环境下基于路侧异源雷达融合的多交通目标鲁棒跟踪方法^{*}

兰浩然, 李旭, 朱建潇, 孔栋

(东南大学仪器科学与工程学院 南京 210018)

摘要:多目标跟踪是保障自动驾驶行驶安全与效率的基础,其获取的数据广泛应用于自动驾驶运动规划、驾驶决策等上层应用。传统多目标跟踪方法在遮挡环境下往往存在目标丢失、错位的现象,针对这一问题,本文提出了基于异源雷达融合与遮挡预测模型的鲁棒跟踪方法。首先,基于激光雷达与毫米波雷达的局部观测一致性方程,提出了一种基于多目标运动约束与全局最大匹配的多传感动态自标定算法。其次,针对完全遮挡环境下因观测数据缺失导致的跟踪中断问题,提出了一种基于异构雷达融合无迹卡尔曼滤波与长短期时序神经网络的混合监督目标位置预测方法。通过实验表明,本文提出的方法在完全遮挡环境下可有效补全至少81%断开的多车辆目标轨迹,且相比于最先进的方法,能够实现更为可靠的多交通目标跟踪。

关键词:目标跟踪;多传感标定;遮挡;路侧感知

中图分类号: TH89 **文献标识码:** A **国家标准学科分类代码:** 460.4020

Robust tracking of multiple traffic targets based on roadside heterogeneous radar fusion in occlusion environment

Lan Haoran, Li Xu, Zhu Jianxiao, Kong Dong

(College of Instrument Science and Engineering, Southeast University, Nanjing 210018, China)

Abstract: Multi-target tracking is the basis to ensure the safety and efficiency of autonomous driving, and the obtained data are widely used in the upper applications of autonomous driving, such as motion planning and driving decision making. The traditional multi-target tracking method often has the phenomenon of target loss and dislocation in the occlusion environment. To solve the problem, a robust tracking method based on heterogeneous radar fusion and occlusion prediction model is proposed. Firstly, based on the local observation consistency equation of lidar and millimeter-wave radar, a multi-sensor dynamic self-calibration algorithm based on multi-target motion constraint and global maximum matching is proposed. Secondly, a hybrid supervised target position prediction method based on heterogeneous radar fusion unscented Kalman filter and long and short time series neural network is proposed to solve the problem of tracking interruption caused by missing observation data in complete occlusion environment. Experiments show that the proposed method can effectively complete at least 81% of the broken multi-vehicle target tracks in the complete occlusion environment, which can achieve more reliable multi-vehicle target tracking compared with the most advanced methods.

Keywords: target tracking; multi-sensor calibration; occlusion; roadside perception

0 引言

随着自动驾驶、智能交通的快速发展,准确可靠的智能路侧感知作为自动驾驶车辆决策规划、交通安全态势评估的关键一环,其受到越来越多的关注与研究。在路

侧设备深度信息感知关键技术环节中,对重点区域多目标车辆的、准确、可靠跟踪是感知车辆位置的核心任务之一。

当前的主流多目标跟踪算法遵循着“先检测后跟踪”的模式,为了实现更加准确的目标检测,越来越多的目标检测算法开始采用多传感器融合的方法,基于多传感融合

收稿日期:2022-06-30 Received Date: 2022-06-30

^{*} 基金项目:江苏省重点研发计划(BE2019106, BE2022053-5)、国家重点研发计划(2018YFB1600803)项目资助

的车辆跟踪一般包括标定、目标检测、目标跟踪。在目标检测方面,基于点云数据的车辆检测技术如今已经得到了很好的发展^[1-4],传统的车辆检测方法也被广泛使用^[5-7]。下面着重回顾多传感标定与跟踪工作。

标定是多传感融合的关键过程,传感器融合对于增强和确保机器感知模块在辅助和自动驾驶中的性能和可靠性至关重要。其中,激光探测及测距(light identification detection and ranging, LiDAR)因其可以在不受光照条件影响的情况下昼夜工作,且点云信息丰富被广泛地采用在算法之中。毫米波雷达点云丰富度劣于激光雷达,但探测距离远,在速度探测方面具有更高的精度,能够极大地帮助目标跟踪算法进行目标的关联分析,从而降低遮挡、环境混杂情况下的编号转换和目标丢失等情况。因此,如何通过毫米波雷达和激光雷达融合来实现多目标车辆跟踪成为了研究的核心问题。目前已经有许多方法用于激光雷达和视觉传感器之间的校准^[8-10],然而很少有毫米波雷达和其他传感器之间的标定方法^[11-14]。Peršić 等^[11-12]基于重投影误差优化和雷达散射截面(radar cross section, RCS)优化完成了激光雷达和毫米波雷达的外部标定;Lee 等^[13]提出了一种基于标定目标位置的时空关系准确地估计毫米波雷达和激光雷达之间时间延迟的方法。Sommer 等^[14]设计了一个简单、低成本的系统,用于校准雷达和 LiDAR 之间的内部硬件时间同步。然而以上校准方法均是基于有目标的,需要手动选择参考系统并且在离线环境下执行校准程序,相比较而言,基于无目标的校准方法使用环境本身作为标定目标,可以通过注册环境中的结构对应关系在线操作,大大提高了标定的自动化水平且更加灵活高效。

多目标车辆跟踪的另一个挑战是遮挡问题,遮挡是指一辆车被另一辆车或其他背景物体遮挡的情况。在复杂城市道路、隧道等环境下,由于遮挡等原因,雷达信号接收往往受阻,导致无法提供准确的观测数据,这将影响车辆跟踪系统的性能和要求。根据遮挡程度,遮挡可分为部分遮挡和完全遮挡^[2,4,15]。Vaquero 等^[16]使用基于规则的方法来识别停车场中部分遮挡的车辆。Lee 等^[17]通过检查在给定的一对车辆之间是否可以看到背景曲线来检测遮挡。Jung 等^[18]开发了一种考虑遮挡推理的视频检测车辆跟踪算法,当检测到遮挡时,算法可以创建一个新的轨迹,并在没有遮挡时将新的轨迹链接到每个轨迹。Zhang 等^[19]开发了一个独特的框架来检测和处理对象遮挡。对象的紧凑度和内部距离比用于帧内级别的遮挡检测,并在帧间级别上应用运动矢量的减法聚类。对于如何解决遮挡问题,可以通过在不同方向设置多个 LiDAR 来消除遮挡问题^[20-21]。Zhao 等^[22]提出了一种基于卡尔曼滤波器的方法来解决遮挡问题。如果当前帧没有检测到物体,

那么算法会在接下来的 1.5 s 内以帧内速度连续搜索物体,如果在 1.5 s 内没有检测到物体,跟踪算法将停止。Song 等^[23]提出了遮挡检测和修复算法,自动合并断开的轨迹,并在 4 个不同的实验场地上进行实验,至少修复了 89% 的断开轨迹。然而这些典型的方法只适用于部分遮挡环境或者短时域内完全遮挡的环境,当车辆长时间处于完全遮挡环境下时,跟踪系统将长时间缺少观测量,使用现有的方法难以实现准确的车辆位置估计,从而导致跟踪中断。

为解决上述问题,本文提出了遮挡环境下基于路侧异源雷达融合的多交通目标跟踪方法。首先,为准确地解决雷达点云之间的配准问题,实现毫米波雷达和激光雷达之间的融合,本文首次提出了一种动态自标定的算法,旨在利用环境特征完成在线标定。其次,为解决遮挡环境下车辆观测数据受阻的问题,实现长时间的可靠跟踪,本文提出了无迹卡尔曼滤波与长短期时序神经网络(unscented kalman filter-long short-term memory, UKF-LSTM)跟踪模型,使用长短期记忆网络(long short-term memory, LSTM)来学习卡尔曼滤波器内部参数与外在观测量之间的关系,以在遮挡环境下为跟踪系统提供连续的观测量。本文方法有效解决了传统多目标跟踪方法在遮挡环境下存在的目标丢失、错位问题,实现了可靠准确的多交通目标跟踪。

1 理论分析

本文的研究内容包含如下 3 个模块:特征提取、动态标定、融合跟踪、高分辨率车辆轨迹获取,整个系统的框架如图 1 所示。

1.1 特征提取

为了实现雷达动态标定,需要进行特征提取,即参照物的点云。首先,接收同步的激光雷达和毫米波雷达原始点云数据。其次,分别对它们独立进行背景过滤和地面分割,提取道路边界和道路平面,最后将车辆特征点云输入检测器对车辆进行检测。

本文的道路边界的检测采用 Wu 等^[24]开发的基于密度的方法。首先,采用 Zhang 等^[25]提出的一种背景自动构造的方法进行背景滤除,背景过滤的目的在于减少输入数据中的无关点云如树木、广告牌等,增加后续算法的处理速度。具体地,Zhang 提出算法将离散的水平垂直角度值视为数字图像中像素点的坐标,利用各方位角的最远距离和平均距离构建背景数据集。然后,根据目标帧数据集与背景数据集之间角值相同的每个点的距离差提取车辆点和行人点。在排除背景后,应用二次帧叠加的方法对代表道路使用者的点进行聚合,进而可以确定聚合点的边界。




图 1 基于 UKF-LSTM 的多目标跟踪系统框架图

Fig. 1 Multi-object tracking system framework

在背景过滤提取到的相关点中存在地面点和道路参与者点云,因此需要通过地面分割将两种类型点云区分开,分别获取道路平面特征点和车辆特征点。本文道路平面的检测采用邱佳月等^[26]提出的基于先验信息采样、一致拟合的激光雷达地面分割方法。该方法首先利用激光雷达点云的先验信息来引导数据采集并对地面模型进行了快速迭代估计,利用点云分布特征因子对地面模型进行评价,最终实现噪声环境下地参考面快速准确的拟合。

1.2 动态标定

标定是传感器融合的关键过程,本文提出的动态标定方法分为粗标定和细标定两个阶段。为了关联两个传感器的数据,本文通过特征提取环节获取到的道路边界、道路平面、车辆点进行动态在线标定,即获取激光雷达和毫米波雷达之间的旋转平移变换参数。不可避免地,特征提取环节输出的车辆点中存在需滤除的噪声点。由于基于密度的空间聚类方法(density-based spatial clustering of applications with noise, DBSCAN)不需要预先定义聚类的数量,这在交通应用中非常关键,因此本研究采用 DBSCAN 作为检测器对车辆和车辆进行聚类分析。

1) 粗标定

对于检测到的同一车辆点,本文选取激光雷达坐标系、毫米波雷达坐标系和地面坐标系,点在 3 个坐标系下表示为 $P_o^i(r_o^i, \theta_o^i, \varphi_o^i)$, $P_l^i(r_l^i, \theta_l^i, \varphi_l^i)$, $P_r^i(r_r^i, \theta_r^i, \varphi_r^i)$, 记 P_l^i 到 P_o^i 的变换参数为 $T_l(t_{x,l}, t_{y,l}, t_{z,l}, r_{x,l}, r_{y,l}, r_{z,l})$, P_r^i 到 P_o^i 的变换参数为 $T_r(t_{x,r}, t_{y,r}, t_{z,r}, r_{x,r}, r_{y,r}, r_{z,r})$, P_l^i 到 P_r^i 的变换参数 $\Delta T(\Delta t_x, \Delta t_y, \Delta t_z, \Delta r_x, \Delta r_y, \Delta r_z)$ 。

当检测到车辆点后,本文采用全局最近邻(global nearest neighbour, GNN)关联两个传感器的数据,两个数据投影到地面坐标系后,采用点之间的欧氏距离建立关联代价矩阵,输入 GNN 得到最优关联,如果距离误差过大将影响 GNN 的关联结果,因此需要粗标定环节减小投影误差。在这个环节中,主要获取雷达到地面坐标系的旋转变换角度参数 $(r_{x,l}, r_{y,l}, r_{z,l})$, $(r_{x,r}, r_{y,r}, r_{z,r})$, 平移变换参数由先验知识获取。由特征提取环节得到的道路边界可以表示为 $Ax + By + C = 0$, 因此可以通过边界的线特征得到方位角。由特征提取环节得到的道路边界可以表示为 $Ax + By + Cz + D = 0$, 因此激光雷达的仰角可以通过拟合的平面方程来获得。

方位角标定的结果不确定性往往较小,标定最大的挑战在于毫米波雷达缺失仰角数据,由于雷达的原始信息中只包含二维几何测量,往往采用雷达平面上的投影点作为物体的位置,将垂直分量的上的误差忽略不计,这将导致物体检测位置与实际位置产生偏移,进而影响后续过程。为了解决上述问题,本文引入毫米波雷达的雷达 RCS 特征,通过以下特性来估计雷达的仰角数据:

当雷达的仰角接近等于 0° 时,雷达中心平面上的点 RCS 值越高,当雷达的仰角接近边界视野范围(field of view, FOV)由雷达参数决定时,雷达平面上的点 RCS 越低。选取 $\alpha \in \rho_H, \beta \in \rho_L, \rho_H \neq \rho_L$ 分别为 RCS 值最高点集和最低点集,则仰角 Φ 的估计可以由关系式(1)得出:

$$\Phi = \frac{X_\beta \sin \varepsilon_f}{X_\alpha - X_\beta \cos \varepsilon_f} \quad (1)$$

其中, x_α 是 α 对应的横向位置, x_β 是 β 对应的横向位置, ε_f 是雷达的最大仰角范围。

2) 细标定

当成功关联到两个传感器的数据后,将激光雷达点和雷达点投影到地面坐标系得到 $P_{l,o}^i(r_{l,o}^i, \theta_{l,o}^i, \varphi_{l,o}^i)$, $P_{r,o}^i(r_{r,o}^i, \theta_{r,o}^i, \varphi_{r,o}^i)$, 为了进一步减少传感器之间的标定误差,获取变换参数 ΔT , 本文引入误差 $\delta_{l,r}$, 定义为 $P_{l,o}^i$ 与 $P_{r,o}^i$ 之间的距离。上述参数关系式如下:

$$P_{l,o,r}^i = P_{l,o}^i \cdot \Delta T \quad (2)$$

$$\delta_{l,r} = \|P_{l,o,r}^i - P_{r,o}^i\| \quad (3)$$

最后,利用 LM 算法最小化误差平方和来获取 ΔT , 参数如式(4)所示。

$$\Delta T = \operatorname{argmin} \left(\sum_{i=0}^N \delta_{l,r}^2 \right) \quad (4)$$

1.3 融合跟踪

正常情况下,基于标定的多雷达数据,使用 GNN 数据关联算法链接前后帧即可实现多交通目标轨迹跟踪。




图2 UKF-LSTM 模型图

Fig. 2 UKF-LSTM model

Stage-1: 假设当前帧为 i , 当系统的观测量未中断时, 使用当前时刻观测量 Z_i 作为 UKF-1 的输入, 可以获取 UKF-1 滤波器的卡尔曼增益 K 以及最优估计 $X_i^{(1)}$ 。选取过去 n 个时间步长的卡尔曼增益 $S_1(K_{i-n}, \dots, K_{i-2}, K_{i-1})$ 以及 Z_i 作为输入输出, 利用 LSTM-1 来训练数据, 同时 LSTM-1 的输出 Z'_i 作为 UKF-2 的输入, 产生新的状态估计值 $X_i^{(2)}$ 。

当系统的观测量中断时, 无法获取 Z_i , 此时 UKF-1 停止更新。LSTM-1 此时根据学习到的滤波参数和观测量之间的关系, 由 $(K_{i-n}, \dots, K_{i-2}, K_{i-1})$ 能够预测得到新的观测量 Z'_i , 并输入到 UKF-2 以保持 UKF-2 的正常工作。Stage-1 在预测环节中的最终输出为 $X_i^{(2)}$ 。

Stage-2: 当前环节的主要作用是利用 LSTM-2 学习最优状态估计值与 UKF-2 之间的差异, 从而对最优状态值进行误差补偿。当系统观测量未中断时, 系统最优状态估计值为 Stage-1 的输出 $X_i^{(1)}$, $X_i^{(2)}$, 由此可以获得两者之间的差异 $X_i^{(3)}$ 。选取过去 n 个时间步长的 $S_2(X_{i-n}^{(3)}, \dots, X_{i-2}^{(3)}, X_{i-1}^{(3)})$ 和当前帧的 $X_i^{(3)}$ 作为 LSTM-2 的输入和输出进行训练。

在帧内每一个车辆的状态估计过程中, 使用检测到的车辆输入测量值, 不断地更新 UKF 滤波器从而获得最优状态。然而, 在路侧视角下, 当车辆被完全遮挡时, 检测器存在在一定时间内丢失对车辆目标的连续可靠观测值的问题。单独使用 UKF 算法进行轨迹跟踪, 在观测值缺失的情况下, 无法更新 UKF 滤波器。具体地, 随着观测中断的时间持续增加, UKF 模型的状态协方差矩阵行列式也将不断增大, 从而导致估计值与真实值之间的误差不断累积。

为了解决此问题, 本文设计了基于 UKF 和 LSTM 融合模型。该模型利用 LSTM 的学习能力建立卡尔曼滤波器内部参数与外在观测量之间的关系。特别是在观测中断的情况下, LSTM 网络仍然能够为卡尔曼滤波器提供连续的观测量, 从而提高整个跟踪过程的性能。本文系统结构如图 2 所示。

当系统的观测量中断时, Stage-1 只输出 $X_i^{(2)}$, LSTM-2 能够预测出当前时刻的差异 $X_i^{(3)}$, 然后与 $X_i^{(2)}$ 共同作用生成最终的状态估计值 X_i 。

整个系统的参数关系如式(5)、(6)所示, 具体算法细节如算法 1 所示。

$$\begin{cases} X_i^{(2)} = f_{ukf-2}(g_{lstm-1}((K_{i-n}, \dots, K_{i-2}, K_{i-1}))) \\ X_i^{(3)} = g_{lstm-2}((X_{i-n}^{(3)}, \dots, X_{i-2}^{(3)}, X_{i-1}^{(3)})) \end{cases} \quad (5)$$

$$X_i = \begin{cases} X_i^{(2)}, & \text{stage-1} \\ X_i^{(2)} + X_i^{(3)}, & \text{stage-1 and stage-2} \end{cases} \quad (6)$$

2 实验验证

2.1 实验设备和场地

本文实验平台配置如下: GPU 为 GeForce RTX 2080Ti, CPU 为 Intel Core i7-12700KF, 实验设备选用 Robosense RS_Lidar_M1 激光雷达和 Continental ARS_408 毫米波雷达进行路侧数据收集, 两个雷达的主要参数如表 1 所示。

算法 1 目标位置预测

输入: Z_i
输出 t : X_i
注: Z_i 为帧 i 中的当前观测值。 K_i 和 $X_i^{(1)}$ 为 UKF-1 的卡尔曼增益和最优估计。 S_1 是过去 n 个时间步的卡尔曼增益序列。 Z'_i 为 LSTM-1 的输出。 $X_i^{(2)}$ 为 UKF-2 的估计值。 $X_i^{(3)}$ 是 $X_i^{(1)}$ 与 $X_i^{(2)}$ 的差值。 S_2 是过去 n 个时间步骤的差值。 X_i 是最终状态估计。

Stage-1:
If 当前的观测 Z_i 没有中断,并且 K_i 和 $X_i^{(1)}$ 可以获得,那么将 K_i 放入序列 S_1 选择 S_1 和 Z_i 作为输入输出训练 LSTM-1。
Else
通过 LSTM-1 预测当前观测 Z'_i , 然后根据式 (5) 更新 UKF-2 获取 $X_i^{(2)}$ 。

Stage-2:
If 当前的观测 Z_i 没有中断,并且 $X_i^{(1)}$, $X_i^{(2)}$ 和 $X_i^{(3)}$ 可以获得,那么将 $X_i^{(3)}$ 放入序列 S_2 。
选择 S_2 和 $X_i^{(3)}$ 作为输入输出训练 LSTM-2。
Else
根据式 (5) 通过 LSTM-2 预测当前差值 $X_i^{(3)}$
根据式 (6) 返回 X_i

表 1 雷达参数表

Table 1 Lidar and radar parameter list

参数	激光雷达	毫米波雷达
频率	10 Hz	77 GHz
范围	0.5~200 m	0.2~250 m
分辨率	±0.03 m	±0.4 m
方位角	±60.0°	±60.0°
仰角	±12.5°	±20.0°

本文选择的实验地点设在南京市太平北路,图 3(a)、(b)展示了路侧传感器的安装位置。

2.2 提出方法的性能分析

在本环节中,将分别验证提出的动态标定和 UKL 模型的性能,根据实验结果分析所提出方法的可靠性。

图 4 展示了粗标定环节中根据 RCS 特性估计仰角值的结果,可以观察到,仰角在达到 9.97° 时 RCS 最大,且 RCS 随着目标与雷达中心平面的距离增大而减小,当到达雷达边界面时达到最小。本次实验中计算出的仰角范围是 0°~9.97°~30°,符合 ARS 雷达的规定参数。

粗标定和细标定的变换参数计算结果如下所示:
 $T_l = (2.5^\circ, 10.23^\circ, -0.12^\circ)$



图 3 实验场地及传感器安装位置
Fig. 3 Experimental site and sensor installation




图 4 RCS 随仰角变化分布图
Fig. 4 RCS distribution with respect to the elevation

$T_r = (0.6^\circ, 9.97^\circ, 1.02^\circ)$
 $\Delta T = (0.01 \text{ m}, 0.19 \text{ m}, 0.02 \text{ m}, 1.8^\circ, 0.82^\circ, 0.07^\circ)$
(7)

为了比较两阶段标定结果的有效性,本文在一定实验时间内,对于道路范围内每辆车的跟踪点,选取激光雷达和雷达之间的跟踪点投影误差作为标定效果的衡量指标。图 5 给出了欧氏距离误差、横向误差、纵向误差。梯状图代表粗标定的误差分布,柱状图代表细标定的误差分布。从图 5 中可以看出,相比于粗标定而言,细标定不仅给出了平移变换参数的最优估计,还在一定程度上对旋转变换参数作出了调整,从而使得整体标定误差显著减少。经过两阶段动态标定后,激光雷达和雷达之间投影点的平均欧氏距离为 0.273 m,低于雷达的距离精度 (0.4 m),验证了本文提出方法的有效性。

此外,还选择了当前最先进的方法与本文的方法进行比较。Peršić 等^[12]提出的方法基于重投影误差优化和 RCS 优化来进行外部校准,记为方法 RCS。本文动态标




图 5 标定误差结果
Fig. 5 Calibration error

定方法和 RCS 方法的误差结果如表 2 所示。虽然本文方法相比于 RCS 性能提升不大,但是本文方法是基于无目标利用环境特征进行标定,整个过程无需手动选择目标参考物,在应用上更加灵活高效。

表 2 与先进方法的标定误差结果对比		
Table 2 Comparison of calibration error results with advanced methods		
距离误差	本文方法	RCS
欧氏	0. 273	0. 282
横向	-0. 074	-0. 096
纵向	0. 013	0. 016

图 6 展示了 UKL 模型的位置预测结果,图中的五角星代表观测中断的开始时刻。在图 6(a)中,车辆 Vehicle-1 在第 462 帧被公交车遮挡从而无法被检测到,UKL 开始预测该车辆位置,直到第 565 帧遮挡消失才重新被检测到,整个观测中断持续时长为 103 帧。同样在图 6(b)中,车辆 Vehicle-2 在第 87 帧被遮挡从而无法被检测到,直到第 181 帧遮挡消失才重新被检测到,整个观测中断持续时长为 94 帧。本文选择了不同的算法进行对比,来验证本文提出方法的可行性。Method-1 是由 Song 等^[23]提出基于 KF 滤波器的轨迹预测算法;Stage-1 是本文提出模型中的一部分,该方法仅使用 Stage-1 环节的预测结果作为整个系统的预测估计值;UKL 包含 Stage-2 环节,并通过该环节来实现误差补偿,以预测最优估计值。

从图 7 可以看出,本文提出的 UKL 模型在观测中断期间表现出了良好的性能。Method-1 在第 462 帧观测中




图 6 不同方法的位置预测结果
Fig. 6 Location prediction results of different methods




图 7 不同方法的位置误差结果
Fig. 7 Location error results of different methods

断开始的 1.5 s (15 帧) 后有逐渐偏离实际位置的趋势, 随着时间的增加, 误差不断累积, 约 30 帧后 Method-1 已无法保持较高精度。

表 3 展示了观测中断期间预测的误差结果, 分别根据 MAX、STD、RMSE 这 3 个指标对比不同的方法。从表中可以看到, Method-1 最大误差分别达到了 13.10 和 15.18 m, 这显然不能满足 GNN 的距离要求。与 Method-1 相比, Stage-1 通过 LSTM 网络的预测能力连续提供观测量, 从而实现了更为精确的位置预测。图 7(a) 中本文提出的 UKL 模型相比于 Stage-1, RMSE 达到了 0.1 m, 相比与 Method-1, Stage-1 分别提高了 98.2%, 94.4%, 图 7(b) 中本文提出的模型 RMSE 达到了 0.13 m, 相比与 Method-1, Stage-1 分别提高了 98.9%, 59.4%, 这也证明了 Stage-2 的优越性。

表 3 与先进方法的预测结果对比

Table 3 Comparison of predication results with advanced methods				
实验	方法	MAX	STD	RMSE
Vehicle-1 位置误差/m	Method-1	13.10	4.29	5.63
	Stage-1	4.54	1.50	1.79
	UKL	1.44	1.39	0.10
Vehicle-2 位置误差/m	Method-1	15.18	1.98	11.91
	Stage-1	7.84	3.89	0.32
	UKL	6.71	1.47	0.13

2.3 与先进方法的对比

为了验证本文提出的跟踪框架的效果, 本文与 Zhao 等^[22] 提出的跟踪方法以及 Song 等^[23] 提出的跟踪方法进行了对比。对比实验分为 3 组, 引入了新指标探测到的轨迹数 (number of detected trajectories, NODT) 和修复轨迹百分比 (percentage of fixed occlusion, POFO) 结果如表 4 所示。

由表 4 可以看出, 相比于没有遮挡处理的方法^[22], 由 Song 等^[23] 提出的方法解决了部分遮挡导致的跟踪中断问题, 并且在完全遮挡环境下也取得了一定的效果。本文提出的方法不仅适用于部分遮挡情况, 并且在长时间完全遮挡环境下依然能够准确预测目标位置, 实验结果表明本文提出的方法至少修复了 81% 的断开轨迹, 有效减少了跟踪中断情况的发生, 验证了本文所提出的跟踪框架的可靠性。

表 4 与先进方法的跟踪结果对比
Table 4 Comparison of tracking results with advanced methods

实验	方法	MOTA/%	NODT	POFO/%	FPS
1	文献[22]	34.1	69	—	36.3
	文献[23]	78.9	21	69.6	27.4
	本文方法	84.5	13	81.2	29.2
2	文献[22]	26.4	314	—	35.2
	文献[23]	75.4	105	66.5	26.9
	本文方法	88.9	47	85.0	28.1
3	文献[22]	24.5	142	—	35.9
	文献[23]	81.9	34	76.1	28.1
	本文方法	90.4	18	87.3	29.5

3 结 论

针对多交通目标跟踪领域内存在的现有问题, 本文提出的方法能够有效修复车辆中断的轨迹, 实现更加有效可靠的多交通目标跟踪。本文的贡献可以总结为如下两方面:

1) 通过提出的动态自标定算法, 在保证标定精度的前提下, 采用了更加灵活高效的标定方式, 完成了多传感之间的配准问题, 获得的基于标定的观测数据为下一步的跟踪环节提供了更为可靠的输入。

2) 提出的 UKL 模型解决了完全遮挡环境下下观测量长时间中断时的目标位置预测问题。但是, 本文仍存在一些不足。首先, 该标定算法适用于能够提取道路边界和平面的环境, 但是面对非结构化路面时, 其效果并不理想。其次, UKL 模型的泛化能力不强, 未来的工作需要继续完善网络, 提高预测能力。

参考文献

[1] CUI Y, XU H, WU J, et al. Automatic vehicle tracking with roadside LiDAR data for the connected-vehicles system[J]. IEEE Intelligent Systems, 2019, 34(3): 44-51.

[2] WU J, XU H, ZHENG J. Automatic background filtering and lane identification with roadside LiDAR data[C]. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), IEEE, 2017: 1-6.

[3] 郑少武, 李巍华, 胡坚耀. 基于激光点云与图像信息融合的交通环境车辆检测[J]. 仪器仪表学报, 2019,

- 40(12):143-151.
- ZHENG SH W, LI W H, HU J Y. Vehicle detection in traffic environment based on laser point cloud and image information fusion [J]. Chinese Journal of Scientific Instrument, 2019, 40(12):143-151.
- [4] WU J, XU H, ZHAO J. Automatic lane identification using the roadside LiDAR sensors[J]. IEEE Intelligent Transportation Systems Magazine, 2018, 12(1):25-34.
- [5] LIN C, GUO Y, LI W, et al. An automatic lane marking detection method with low-density roadside LiDAR data[J]. IEEE Sensors Journal, 2021, 21(8):10029-10038.
- [6] LIU Z, LI Q, MEI S, et al. Background filtering and object detection with roadside lidar data[C]. 2021 4th International Conference on Electron Device and Mechanical Engineering (ICEDME), IEEE, 2021: 296-299.
- [7] CUI Y, WU J, XU H, et al. An automatic triggered rectangular rapid flashing beacons (RRFB) system using the roadside LiDAR sensor[J]. IEEE Access, 2019, 7: 163831-163839.
- [8] LE GENTIL C, VIDAL-CALLEJA T, HUANG S. 3D lidar-imu calibration based on upsampled preintegrated measurements for motion distortion correction[C]. 2018 IEEE International Conference on Robotics and Automation (ICRA), IEEE, 2018: 2149-2155.
- [9] JEONG J, CHO Y, KIM A. The road is enough! Extrinsic calibration of non-overlapping stereo camera and LiDAR using road information[J]. IEEE Robotics and Automation Letters, 2019, 4(3):2831-2838.
- [10] 彭梦, 陈白帆, 邓作杰, 等. 2D 激光雷达和摄像机最小解标定的多解筛选及参数优化[J]. 仪器仪表学报, 2021, 42(7):89-97.
- PENG M, CHEN B F, DENG Z J, et al. Multi-solution screening and parameter optimization for minimum solution calibration of 2D lidar and camera [J]. Chinese Journal of Scientific Instrument, 201, 42(7):89-97.
- [11] PERŠIĆ J, MARKOVIĆ I, PETROVIĆ I. Extrinsic 6DoF calibration of 3D lidar and radar[C]. 2017 European Conference on Mobile Robots (ECMR), IEEE, 2017: 1-6.
- [12] PERŠIĆ J, MARKOVIĆ I, PETROVIĆ I. Extrinsic 6dof calibration of a radar-lidar-camera system enhanced by radar cross section estimates evaluation[J]. Robotics and Autonomous Systems, 2019, 114: 217-230.
- [13] LEE C L, HSUEH Y H, WANG C C, et al. Extrinsic and temporal calibration of automotive radar and 3D LiDAR[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2020: 9976-9983.
- [14] SOMMER H, KHANNA R, GILITSCHENSKI I, et al. A low-cost system for high-rate, high-accuracy temporal calibration for LIDARs and cameras[C]. 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2017: 2219-2226.
- [15] SUN Y, XU H, WU J, et al. 3-D data processing to extract vehicle trajectories from roadside LiDAR data[J]. Transportation Research Record, 2018, 2672(45): 14-22.
- [16] VAQUERO V, DEL PINO I, MORENO-NOGUER F, et al. Deconvolutional networks for point-cloud vehicle detection and tracking in driving scenarios [C]. 2017 European Conference on Mobile Robots (ECMR), IEEE, 2017: 1-7.
- [17] LEE H, COIFMAN B. Side-fire lidar-based vehicle classification [J]. Transportation Research Record, 2012, 2308(1): 173-183.
- [18] JUNG Y K, HO Y S. Traffic parameter extraction using video-based vehicle tracking[C]. Proceedings 199 IEEE/IEEEJ/SAI International Conference on Intelligent Transportation Systems (Cat. No. 99TH8383), IEEE, 1999: 764-769.
- [19] ZHANG W, WU Q M J, YANG X, et al. Multilevel framework to detect and handle vehicle occlusion [J]. IEEE Transactions on Intelligent Transportation Systems, 2008, 9(1): 161-174.
- [20] LI B, ZHANG T, XIA T. Vehicle detection from 3D lidar using fully convolutional network [J]. ArXiv Preprint, 2016, ArXiv:1608.07916.
- [21] THORNTON D A, REDMILL K, COIFMAN B. Automated parking surveys from a LIDAR equipped vehicle[J]. Transportation Research Part C: Emerging Technologies, 2014, 39: 23-35.
- [22] ZHAO J, XU H, LIU H, et al. Detection and tracking of

- pedestrians and vehicles using roadside LiDAR sensors[J]. *Transportation Research Part C: Emerging Technologies*, 2019, 100: 68-87.
- [23] SONG X, PI R, LV C, et al. Augmented multiple vehicles' trajectories extraction under occlusions with roadside LiDAR data[J]. *IEEE Sensors Journal*, 2021, 21(19): 21921-21930.
- [24] WU J, XU H, ZHAO J. Automatic lane identification using the roadside LiDAR sensors[J]. *IEEE Intelligent Transportation Systems Magazine*, 2018, 12(1): 25-34.
- [25] ZHANG Z, ZHENG J, XU H, et al. Automatic background construction and object detection based on roadside LiDAR [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(10): 4086-4097.
- [26] 邱佳月, 赖际舟, 李志敏, 等. 面向复杂场景的激光雷达地面分割算法[J]. *仪器仪表学报*, 2020, 41(11): 244-251.
- QIU J Y, LAI J ZH, LI ZH M, et al. Ground segmentation algorithm based on lidar for complex scene [J]. *Chinese Journal of Scientific Instrument*, 2020, 41(11): 244-251.

作者简介



兰浩然, 2020 年于安徽工业大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为基于多传感融合的环境感知技术。
E-mail: 179621045@qq.com

Lan Haoran received his B.Sc. degree from Anhui University of Technology in 2020. He is currently a master student at Southeast University. His main research interests include environment sensing technology based on multi-sensor fusion.



李旭(通信作者), 2006 年于东南大学获得博士学位, 现为东南大学仪器科学与工程学院教授, 主要研究方向为车辆导航定位、环境感知及自主控制。
E-mail: lixu.mail@163.com

Li Xu (Corresponding author) received his Ph.D. degree from Southeast University in 2006. He is currently a professor in the School of Instrument Science and Engineering at Southeast University. His main research interests include vehicle navigation and positioning, environment perception and autonomous control.