

# 多传感器融合无人驾驶同时定位与建图技术发展研究

曾贵萍 唐阳

(西南交通大学机械工程学院,成都 610031)

【欢迎引用】曾贵萍,唐阳.浅析多传感器融合无人驾驶SLAM技术研究现状[J].汽车文摘,2025(8):14-24.

【Cite this paper】ZENG G P, TANG Y. Analysis of the Research Status of Multi-Sensor Fusion Unmanned SLAM[J]. Automotive Digest (Chinese), 2025(8): 14-24.

【摘要】同时定位与建图(SLAM)技术是目前研究的热点和难点,是实现无人驾驶的关键技术之一。文中围绕SLAM原理、基本结构、所使用传感器以及地图类型展开介绍,分析各种融合方法的优缺点及适用范围。其次根据采用的融合方法不同,分别介绍了国内外研究现状,并指出其值得肯定和延续的技术以及存在的不足。最后,总结目前多传感器融合无人驾驶SLAM研究的问题,分析研究难点并对未来研究可能的发展方向提出建议,以期为无人驾驶的发展提供参考。

关键词:多传感器融合;同时定位与建图;无人驾驶;信息融合方法

中图分类号:U463.6 文献标志码:A DOI:10.19822/j.cnki.1671-6329.20230197

## Analysis of the Research Status of Multi-Sensor Fusion Unmanned SLAM

Zeng Guiping, Tang Yang

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031)

【Abstract】The technology of Simultaneous Localization And Mapping(SLAM)is the hot and difficult point of current research. It is one of the key technologies to realize unmanned driving. The paper introduction is centered on the principle, basic structure, sensors used and map types of SLAM and analyzes the advantages, disadvantages and scope of application of various fusion methods. Secondly, according to the different fusion methods used, it introduces the current status of research at home and abroad, and points out its worthwhile affirmation and continuation of the technology as well as shortcomings. Finally, it summarizes the current problems of multi-sensor fusion unmanned SLAM research, analyzes the research difficulties and puts forward suggestions on the possible development direction of future research, with the aim of providing references for the development of unmanned driving.

Key words: Multi-sensor Fusion, Simultaneous Localization And Mapping (SLAM), Unmanned Driving, Information Fusion methods

## 0 引言

近年来,随着人工智能技术的进步,自动驾驶汽车快速发展<sup>[1]</sup>。为确保准确的环境感知能力,自动驾驶汽车普遍配备多种传感器。融合多传感器技术成为研究重点,主要包括相机、激光雷达、毫米波雷达、惯性测量单元(Inertial Measurement Unit, IMU)以及轮式里程计等。融合多传感器技术的核心在于充分发挥各传感器优势,实现对周围环境的全面感知。

同时定位与建图(Simultaneous Localization And Mapping, SLAM)技术是该领域的重要技术之一。在

隧道、地下停车场、高楼林立和遮挡等环境中,定位信息通常较弱<sup>[2]</sup>,自动驾驶汽车无法准确获取自身定位信息。SLAM技术可以在未知环境中获取自身相对定位信息并重建周围环境<sup>[3-4]</sup>,有效解决上述问题。目前,许多研究者已经取得了显著成果。美国卡内基梅隆大学机器人研究所<sup>[5]</sup>提出了一种基于快速增量矩阵分解的SLAM方法,即增量平滑和建图(Incremental Smoothing And Mapping, ISAM)。香港科技大学<sup>[6-7]</sup>提出了一种实时单目视觉惯性状态估计框架(Visual-Inertial System-Monocular, VINS-Mono)和一种基于优化的多传感器状态框架(Visual-Inertial System-

Fusio, VINS-Fusion), 可实现自主应用的精确自定位。浙江大学的成果<sup>[8-9]</sup>主要包括鲁棒关键帧单目同时定位与建图 (Robust Keyframe-based monocular SLAM, RKSLAM)<sup>[8]</sup>、用于AR的基于关键帧的鲁棒单目SLAM系统以及实时同步定位和建图系统 (Real-time Dynamic SLAM, RDSLAM)<sup>[9]</sup>。本文对多传感器融合的研究现状进行分析, 总结其目前存在的问题及技术难点, 并对其未来发展及研究方向提出建议。

## 2 SLAM基本介绍

SLAM技术通过在未知环境中建立地图并跟踪位置实现对车辆的导航与定位。目前, 应用最广泛的SLAM方法主要包括激光SLAM和视觉SLAM。根据构建地图的维度, 激光SLAM可分为2D激光SLAM和3D激光SLAM。根据图像信息处理方式, 视觉SLAM可分为稀疏、半稠密和稠密3种类型<sup>[10]</sup>。此外, 多传感器相互融合SLAM算法, 可以有效提升SLAM系统的鲁棒性、准确性和环境适应性, 有助于实现复杂环境下的精确定位和地图构建。

### 2.1 SLAM框架及原理

SLAM系统主要由传感器数据、前端、后端、回环检测和建图5个部分组成<sup>[11]</sup>。视觉SLAM(图1)和激光雷达SLAM(图2)的系统架构存在差异。传感器将获取的环境信息作为输入, 实现数据读取。前端模块主要进行数据预处理和数据关联, 完成连续帧数据之间的特征关联。后端模块接收来自前端和回环检测的数据, 进行数据优化, 提高定位的精度。回环检测模块用于识别主体是否重返已经过的区域, 对比数据偏差, 减少累计误差。建图模块接收后端优化的数据, 建立地图并保存主体运动轨迹。




图1 视觉SLAM系统框架

SLAM过程可通过2个基本方程表示<sup>[12]</sup>, 分别为运动方程和观测方程:

$$\begin{cases} x_k = f(x_{k-1}, u_k, w_k) \cdots \\ z_{k,j} = h(y_j, x_k, v_{k,j}) \cdots \end{cases} \quad (1)$$

式中:  $x_k$  为物体在  $k$  时刻时的位置,  $u_k$  为运动传感器的读数(即输入),  $w_k$  为噪声。

函数  $f$  为任一运动传感器, 其为一个通用的方程而不必限定于某个特殊的传感器上,  $y$  为路标点,  $v_{k,j}$  为本次观测噪声, 即当主体在  $x_k$  位置上看到某个路标点  $y_j$ , 将产生一个观测数据  $z_{k,j}$ 。




图2 激光雷达SLAM系统框架

### 2.2 SLAM基础理论概述

#### 2.2.1 旋转群 $SO(3)$ 及其李代数

由所有旋转矩阵组合的集合为特殊正交群  $SO(3)$  与对应的李代数  $so(3)$ , 其包含的元素为反对称矩阵<sup>[13]</sup>。设  $\omega = [\omega_x, \omega_y, \omega_z]$ , 则有运算符  $(\cdot)$  将三维向量映射为反对称矩阵:

$$\hat{\omega} = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix} \cdots \quad (2)$$

而运算符  $(\cdot)$  则将反对称矩阵映射为三维向量:

$$\begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix} = \omega \cdots \quad (3)$$

指数映射与对数映射为:

$$R = \text{Exp}(\theta) = \exp(\hat{\theta}) \quad (4)$$

$$\theta = \text{Log}(R) = \log(R)^\sim \cdots \quad (5)$$

式中:  $\theta$  为  $\omega$  对应到李群上的李代数,  $R$  为指数映射。

关于2个李代数指数映射之间的乘积的对数映射, 由 Baker-Campbell-Hausdorff (BCH)<sup>[14]</sup> 公式展开可得:

$$\ln(\exp(A)\exp(B)) = A + B + \frac{1}{2}[A, B] + \frac{1}{12}[A, [A, B]] - \frac{1}{12}[B, [A, B]] \cdots \quad (6)$$

式中:  $[\cdot]$  表示李括号运算,  $A$  和  $B$  为一般线性运算符。

若其中一个李代数为小量时, 可以进行近似展开:

$$\begin{cases} \ln(\exp(\hat{\phi}_1)\exp(\hat{\phi}_2)) \approx \\ \begin{cases} J_l(\hat{\phi}_2)^{-1}\hat{\phi}_1 + \hat{\phi}_2, \text{ if } \hat{\phi}_1 \text{ is small} \\ J_l(\hat{\phi}_1)^{-1}\hat{\phi}_2 + \hat{\phi}_1, \text{ if } \hat{\phi}_2 \text{ is small} \\ \dots \end{cases} \\ J_l = \frac{\sin \theta}{\theta} I + \left(1 - \frac{\sin \theta}{\theta}\right) a a^T + \frac{1 - \cos \theta}{\theta} \hat{a} \\ J_l^{-1} = \frac{\theta}{2} \cot \frac{\theta}{2} I + \left(1 - \frac{\theta}{2} \cot \frac{\theta}{2}\right) a a^T - \frac{\theta}{2} \hat{a} \end{cases} \quad (7)$$

式中: $\varphi$ 为对应到李群上的李代数的向量, $J$ 为指数映射泰勒展开式运算结果, $\theta$ 为模长, $\alpha$ 为方向,且 $J_r(\phi) = J_l(-\phi)$

在SLAM优化问题中,需求解旋转或位姿的导数。用李群表示旋转或位姿后,左或右乘会产生扰动,对扰动求导的方法为扰动模型。假设空间点 $P$ 旋转得到 $RP$ ,旋转和位姿的扰动模型为:

$$\frac{\partial(RP)}{\partial\varphi} = -(RP)\hat{\cdot}\dots \quad (8)$$

式中: $\varphi$ 为 $R$ 对应的李代数,则旋转后的点相对于旋转矩阵的导数为 $-(RP)\hat{\cdot}$ 。

考虑位姿变换矩阵的情况,对于一个空间点 $P$ 进行位姿变换 $T$ (对应的李代数为 $\xi$ ),得到 $P'=TP$ ,则变换的点相对李代数的导数为 $(TP)\hat{\circ}$ 。

$$\frac{\partial(TP)}{\partial\delta\xi} = \begin{bmatrix} I & -(RP + t) \\ 0^T & 0 \end{bmatrix} = (TP)\hat{\circ}\dots \quad (9)$$

式中: $\delta\xi$ 为扰动项的李代数, $\xi$ 为 $T$ 对应的李代数。

### 2.2.2 四元数相关运算

四元数 $q$ 相对于向量 $\alpha$ 求导,计算步骤可表示为:

$$\frac{\partial(q \otimes a \otimes q^*)}{\partial a} = \frac{\partial(R\{q\})}{\partial a} = r(q)\dots \quad (10)$$

四元数 $q$ 相对于四元数 $\alpha$ 求导,计算步骤如下:

$$\frac{\partial(q \otimes a \otimes q^*)}{\partial a} = 2[q_w a + q_v \times a | q_v^T a I_{3 \times 3} + (q_v a^T - q_w \hat{a}) \dots \quad (11)$$

四元数 $q$ 相对于选择增量 $\delta\theta$ 求导,计算步骤如下:

$$\frac{\partial(q \otimes a \otimes q^*)}{\partial\delta\theta} = \frac{\partial(R\{q\}a)}{\partial\delta\theta} = -R\{\theta\}a\hat{J}_r(\theta)\dots \quad (12)$$

### 2.2.3 非线性优化

SLAM中的优化问题,可以表示为非线性最小二乘问题,故求解前者可求解后者的最优值问题。本文以最小二乘法<sup>[15]</sup>问题为例。

$$\min_x F(x) \frac{1}{2} \|f(x)\|_2^2 \dots \quad (13)$$

式中: $x$ 为自变量, $f(x)$ 为任意非线性函数。

该最小二乘问题由于复杂性无法直接求解极小值,常使用高斯牛顿法<sup>[16]</sup>和列文伯格-马夸尔特法<sup>[17]</sup>进行迭代,使结果无限接近极小值。

高斯牛顿法的增量方程为:

$$J(x)J^T(x)\Delta x = -J(x)f(x)\dots \quad (14)$$

式中: $J(x)$ 为 $f(x)$ 关于 $x$ 的导数。

列文伯格-马夸尔特法的增量方程为:

$$(J(x)J^T(x) + \lambda I)\Delta x = -J(x)f(x)\dots \quad (15)$$

式中: $J(x)$ 为 $f(x)$ 关于 $x$ 的导数。

## 2.3 SLAM使用的传感器

### 2.3.1 摄像头

摄像头在SLAM系统中主要用于目标检测,实现目标识别与跟踪、构建地图<sup>[18]</sup>。摄像头可分为单目、双目、深度和事件摄像头,适用于不同的情况和需求。

单目摄像头的测距原理为通过图像匹配进行目标识别,根据目标对象在图像中的尺寸估计距离<sup>[19]</sup>。单目摄像头在计算各点之间的距离时将出现比例因子漂移。

双目摄像头由2个单目摄像头组成,二者的距离固定,通过匹配和三角剖分估计深度信息。2个单目摄像头的分辨率和基线将影响双目摄像头的深度范围。摄像头视场重叠区域越宽,基线越宽,估计深度越精确。De Croce等<sup>[20]</sup>提出了S-PTAM立体SLAM系统的分布式体系结构,该系统允许定位模块在机载操作,映射模块在远程基站上运行,从而降低了嵌入式处理器的计算负荷。

深度摄像头可以直接提供像素深度,包括纹理信息和实时环境的3D结构。通过立体成像、结构光或飞行时间等方法实现空间信息的度量,主要用于室内导航。

基于事件的相机(Dynamic Vision Sensor, DVS)是一种受生物启发的新型传感器,可以根据每个像素的光强变化提供微秒分辨率的异步事件流<sup>[21]</sup>。每个时间均包含位置、时间戳和极性信息,并被连续记录。与传统图像传感器相比,其具有高时间分辨率、高动态范围、无运动模糊、低延迟、带宽和功耗优势<sup>[22]</sup>。

### 2.3.2 激光雷达

激光雷达向周围发射激光脉冲,通过飞行时间法获得扫描点到中心的距离,具有频率高、精度高、距离远以及不受光照影响的优点<sup>[23]</sup>。激光雷达反射测量能够提供更多关于场景结构的额外信息,故其可以在室内或室外环境中使用,并可以再现2D或3D表示。相比于雷达,激光雷达扫描次数更多,扫描点密度更高,激光雷达的分辨率也更高。

### 2.3.3 毫米波雷达

毫米波雷达可以检测远处物体的存在状态、大小、速度和方向,且能够在雾、雨、雪等极端天气条件下工作。毫米波雷达技术通常结合脉冲多普勒和调频连续波使用<sup>[12]</sup>。脉冲多普勒技术通过发射无线电波并接受反射波,利用反射波长的变化精确测量物体速度。而调频连续波技术则基于连续发射的载波频率,通过分析返回回波提取有效信息,如接收信号的

往返延迟或收发信号频率差<sup>[24]</sup>。因此,目标检测精度取决于目标的大小、距离、吸收特性和反射角。一般来说,雷达的探测距离与其开角成反比关系。

一般来说,雷达传感器在区分静止目标和回波方面存在局限性<sup>[25]</sup>。现有技术倾向于采用附加处理来减小测量误差。由于传感器角度分辨率的限制,目前汽车雷达传感器在单个采样回路中进行检测的情况相对较少<sup>[26]</sup>。现有雷达目标识别方法主要利用频域中的拍频信息。然而,已有研究开始关注静止和运动物体的雷达信号特征,并将其映射至时频谱<sup>[27]</sup>。

目前的雷达传感器通常受多种因素影响,如假正、假负、距离和角度误差等,从而导致噪声产生。用户可以先通过制造商提供的软件或者直接处理原始传感器数据的方法减低噪声。制造商所提供的软件通常不公开其处理方法的详细信息;直接处理原始传感器数据也无法完全避免噪声问题。雷达比激光雷达和相机更易产生噪声,因为其对表面反射率和反射器姿态高度敏感。此外,多径干扰会在连续帧之间引起不一致性问题,导致更多噪声和异常值,从而产生更多假警报<sup>[28]</sup>。

#### 2.3.4 IMU

IMU由3个加速度计和3个陀螺仪组成<sup>[29]</sup>。其中,加速度计可以测量空间 $x$ 、 $y$ 、 $z$ 方向上的线性加速度,陀螺仪用于获得围绕3个旋转轴(滚转、俯仰和偏航)的角速度。IMU通过结合运动模型和时间测量积分的信息,从测量中推断相对于前一个位置的位置( $x$ 、 $y$ 、 $z$ )和方向( $\theta_x$ 、 $\theta_y$ 、 $\theta_z$ )<sup>[30]</sup>。估计步长通常通过滤波器(如卡尔曼滤波器)获得,其提供了位置、方向和速度的估计值。定位过程采用积分法,通过逐级计算位移更新载体相对于原点的位置和方向。由于位置计算结果依赖测量值的积分过程,该传感器在运动过程中表现出漂移迅速累积现象。因此,IMU不能单独用于进行精确的姿态估计,通常需与其他传感器数据进行融合,以校正漂移并提高姿态估计的精度。

#### 2.3.5 轮速里程计

地面车辆的车轮通常配备编码器,用于计算车轮的旋转次数,从而估计行驶的距离和车辆相对于其起点的位置和方向<sup>[31]</sup>。然而,车轮里程计在实际应用中存在累计误差(即漂移)。此误差主要源于车轮在行驶过程中因滑动导致的抓地力损失,且随车辆行驶逐渐增大。误差的可变性受到地面的平整程度(光滑或粗糙的地面)和车辆行驶轨迹(直线或弯道)的影响。

## 2.4 地图类型及应用场景介绍

在SLAM中常见的地图类型主要包括拓扑地图、网格地图、基于地标的地图、点云地图、语义地图和栅格地图<sup>[32]</sup>。上述地图种类在环境表现形式、所需数据以及适用传感器方面存在显著差异。本节将对各类地图的定义、优劣势及其适用环境进行详细阐述。

### 2.4.1 拓扑地图

在拓扑地图<sup>[33]</sup>中,每个节点代表一个特定位置,边则代表各位置之间的路径连接关系。在实际建图过程中,主体每到达一个新的位置就产生一个新的节点。拓扑地图具有结构紧凑、高效的特点,但其在描述大型环境时存在局限性,且定位精度相对较低。

### 2.4.2 3D网格地图

3D网格地图通常基于八叉树<sup>[34]</sup>构建,其每个节点可以递归细分为8个子节点。这种结构不仅有利于合并来自不同传感器的信息,而且可以提高感兴趣领域的分辨率。

### 2.4.3 基于地标的地图

基于地标的地图通过具有明显特征和对应空间坐标的3D地标来描述环境<sup>[35]</sup>。这种地图对环境进行离散化处理,需处理的数据量相对较少,因此对存储和计算资源的要求较低适用于具有显著特征的环境。

### 2.4.4 点云地图

点云地图直接利用传感器的点云信息构建密集地图,能够提供丰富的环境信息<sup>[36]</sup>。但是在实际应用中,点云地图的数据量过于冗余,且不适用于大规模场景建图。因此,点云地图主要用于局部区域建图,还可用于建立离线的全局地图。

### 2.4.5 语义地图

语义地图结合了几何信息和语义信息,为环境中的每个区域添加语义信息<sup>[37]</sup>。不同的颜色表示不同的语义含义,提供比其他地图更高层次的信息。语义地图中丰富的语义信息有助于自动驾驶汽车在复杂的环境中作出更明智的决策。

### 2.4.6 栅格地图

栅格地图<sup>[38]</sup>由多个栅格构成,每个栅格单元可被赋值,数值越大栅格被占据的概率越大,初始值为50%。栅格地图不仅有利于保存和维护数据,而且不受地形影响<sup>[39]</sup>。然而,在大型环境中,栅格地图需存储所有障碍物的信息,导致数据量较大,在后续研究中需更简化的算法来提高其实时性。表1总结了不同地图类型的优劣势和应用场景。

表1 6种地图优劣势及应用场景

地图名称	优势	劣势	应用场景
拓扑地图	表示方法高效且紧凑,路径规划效率高	不容易扩展到大型环境中,泛化性差	适用于小范围场景且空间复杂度低的场景中
网格地图	树状结构有利于融合各传感器信息,感兴趣区域的分辨率高	受传感器获取信息的可靠性影响大	适用于环境标志物明显的区域
基于地标的地图	离散化表示环境信息,可减少数据量	环境需具有明显的纹理特征,否则算法会因无法检测地标而失效	适用于存在大量且明显的地标场景中
点云地图	能够在模型中尽可能地保留原始的环境信息,同时能够有效描述环境	由于其存储大量无序的三维数据点,随之会带来大量的存储和运算问题,无法做到对数据进行实时处理	适用于局部且需提供详细信息的场景
语义地图	信息丰富,建图效果好	需大量数据和计算资源	适用于室内场景和车道识别、自由空间提取等场景
栅格地图	简化的表示方式有利于合并来自不同传感器的信息	仅能存储二维环境中的障碍信息,无法对周围环境进行更丰富的描述	适用于路径短的场景和导航

### 3 多传感器融合研究现状及存在问题

在自动驾驶技术领域中,仅采用单一传感器无法实现完全无人驾驶,也无法应对多样化的驾驶环境。多传感器融合的核心在于其可以综合多个传感器采集的数据,增强了信息的完整性和精确度<sup>[40]</sup>。多传感器融合技术成为必然趋势。

#### 3.1 多传感器融合方法概述

多传感器融合技术将收集的信息进行综合分析,进行多层次、多空间信息优化组合,更全面而准确的描述环境信息。融合后的信息具有及时性、冗余性、互补性和低成本性,可以提高系统的可靠性与稳定性<sup>[41]</sup>。根据数据处理机制,可以将融合方法分为分布式、集中式和混合式3种类型<sup>[42]</sup>。根据信息处理的程度不同可将其分为像素级、特征级和决策级3种类型<sup>[43]</sup>。根据融合位置不同可将其分为前融合、中融合和后融合3种类型<sup>[44]</sup>。

在融合系统框架<sup>[45]</sup>中,目标识别过程包括以下8个阶段:传感器采集数据、数据采集预处理、特征提取与选择、目标分类识别、信息处理、数据对准与识别、分类以及识别结果。如图3所示。分布式融合方法独立处理传感器采集的原始数据,对处理后的数据进行优化组合,最终输出综合结果,该方法可以有效降低算力,提高数据传输可靠性。如图4所示,集中式融合方法则是在中央处理器中直接融合传感器采集的原始数据,该方法虽然可以减少数据在传输过程中的损失,但处理大量数据时对计算能力的要求较高。如图5所示,混合式融合方法结合了分布式与集中式的特点,其数据传输可靠性好,且损失率低,但结构复杂,鲁棒性低。




图3 分布式结构工作原理




图4 集中式结构工作原理

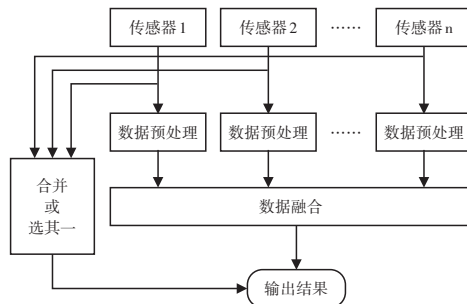


图5 混合式结构工作原理

像素级融合方法属于初始数据融合,主要针对同类型传感器采集的原始数据进行融合,如图6所示。该方法尽可能减少了数据丢失,保证数据准确,但数据计算量大,受环境和数据传输干扰大,无法处理不同数据格式。特征级融合方法则是对传感器原始数据进行特征提取之后再融合,如图7所示,该方法通过抽象数据特征,降低了数据量,提高了融合效率。决策级融合方法是对数据进行特征提取并识别之后再融合,如图8所示,其动态性高、容错性高、鲁棒性强。




图6 像素级融合工作原理




图7 特征级融合工作原理




图8 决策级融合工作原理

前融合即原始数据融合,常见的前融合方法为将雷达点云数据投影至相机图像中,以此增强图像的深度信息。中融合即特征数据融合,是指从不同的传感器原始数据中提取特征并进行整合,该方法的核心在于坐标转换,需确保所有特征在同一坐标系中进行融合。后融合方法则是在特征提取和分类识别之后进行的融合,即对感知结果进行融合。各感知部分不存在耦合关系,可以逐个优化,具有较强实用性。

### 3.2 多传感器融合研究现状

在SLAM领域,采用单一传感器进行环境感知实现定位与建图存在显著局限性<sup>[46]</sup>。视觉传感器易受光照影响,在纹理薄弱的场景中,特征点易丢失。此外,视觉传感器视角受限,无法获取全面的场景信息。但是相较于激光雷达,视觉传感器可以在有限范围内获得更丰富的信息。激光雷达不受光照条件影响,测量范围较广,可以在水平方向实现360°全覆盖,并且具有较高扫描精度。因此,结合视觉传感器与激光雷达的优势进行定位与建图,可以实现对周围环境更全面的精准感知。

最早关于相机和激光雷达数据融合研究<sup>[47]</sup>主要基于激光雷达SLAM中的回环检测提供视觉特征。虽然激光测量用于构建3D环境地图,但回环检测是在连续图像上计算相似性来度量的,而非单个图像。此

方法在相似性矩阵上使用基于特征值的技术,仅考虑非典型或感兴趣特征进行匹配,以降低误差。现有研究中的融合方案主要分为紧耦合与松耦合2大类<sup>[32]</sup>。

#### 3.2.1 紧耦合融合方案

紧耦合融合方案将视觉SLAM和激光雷达SLAM融合于同一系统框架内,协同构建运动方程和观测方程并进行状态估计<sup>[48]</sup>。在该方案中,视觉和激光雷达融合处于同一状态向量中,以二者的残差项作为误差项,同时优化状态变量。该方法直接利用传感器原始数据进行特征层面的融合,具有较高的准确性。以下为5种具体的紧耦合融合方法实例。

(1)VIL-SLAM。结合双目视觉、惯性和激光雷达的同时定位与建图(Visual Inertial Lidar-SLAM, VIL-SLAM)<sup>[49]</sup>是一种立体视觉、惯性和激光雷达里程计的耦合方法。该方法首先使用Kanade Lucas Tomasi算法跟踪立体匹配中的特征点。若特征点数量不足,采用Shi-Tomashi算法进行特征提取。然后,计算快速特征点提取和描述法(Oriented FAST and Rotated Brief, ORB)描述符,并进行立体匹配,并将匹配结果与IMU测量值结合,进行位姿图平滑处理。最后,通过点云迭代最近点法(Iterative Closest Point, ICP)将处理结果与激光雷达模块进行对齐,加入全局位姿增量优化,实时进行轨迹和姿态校正。

(2)LC-LVF。低成本激光雷达和视觉融合方法(Low-Cost Lidar and Vision Fusion, LC-LVF)<sup>[50]</sup>采用成本函数,使用点云和图像数据约束位姿图优化。该方法首先通过scan-to-scan或者scan-to-map估计当前位姿,并使用ORB特征估计运动并生成词袋。其次,使用通用图优化(General Graph Optimization, G2O)进行位姿图优化。最后,将优化后的位姿图应用于基于词袋的方法进行回环检测。该方法建立的地图可以用于快速定位,对动态对象检测具有一定的参考意义。

(3)TVLO。紧耦合视觉-激光雷达里程计法(Tightly coupled, Visual-Lidar Odometry, TVLO)<sup>[51]</sup>采用实时激光雷达里程计和建图法(Lidar Odometry and Mapping in Real-time, LOAM)生成地图,并通过ORB-SLAM2实现地图可视化。该方法通过上述2个模块独立提取特征并进行匹配,最后通过添加几何约束进行准确的运动估计。在激光雷达模块,点对线和平面的距离形成残差。在视觉模块,点的单目投影和立体投影形成残差。在特征跟踪中,使用列文伯格-马夸尔特非线性优化最小化残差,结果更新至激光雷达地

图中。通过 Ceres 进行循环检测使激光雷达点云均匀分布,光束平差法(Bundle Adjustment, BA)优化,然后更新至视觉可视化地图中。此方法虽精度较高,但实时性还需进一步提高。

(4)LIC-Fusion 2.0。基于激光雷达惯性相机里程计的第二代算法(Lidar-inertial-camera fusion 2.0, LIC-Fusion 2.0)<sup>[52-53]</sup>采用多状态约束下的卡尔曼滤波器(Multi-State Constraint Kalman Filter, MSCKF)框架融合激光雷达扫描的边缘特征、稀疏的 FAST 视觉特征和 IMU 测量值,通过基于滑动窗口特征跟踪处理激光雷达点云。此方法提出了一种处理异常值的准则,最小化激光雷达帧间变换的不确定性实现鲁棒匹配,从而减小了激光雷达扫描与 ICP 的匹配误差。

(5)R2LIVE。鲁棒的、实时的、激光雷达-惯性-视觉紧耦合状态估计与建图法(Robust, Real-Time, LiDAR-Inertial-Visual Tightly-Coupled State Estimator and Mapping, R2LIVE)<sup>[54]</sup>在卡尔曼滤波器中融合视觉、激光雷达和惯性传感器的数据,并基于高速率滤波器的里程计和低速率因子图进行优化,提高了系统的实时性。

此外,蔡英凤等<sup>[55]</sup>通过融合激光雷达、摄像头和 IMU 的信息,使用点云深度信息补偿并优化视觉特征,在紧耦合框架中将激光雷达信息直接嵌入视觉惯性系统,从而提高了系统的精度和稳定性。

### 3.2.2 松耦合融合方案

松耦合方法将视觉 SLAM 和激光雷达 SLAM 作为 2 个独立的模块,各传感器独自进行运动估计,最后将估计结果进行融合。该方法对视觉信息和激光雷达信息分别进行优化,融合了优化结果,故其运算速度快,对算力要求不高,但存在准确性不足的问题。以下为 3 种具体的松耦合融合方法实例。

(1)LIMO。激光雷达单目视觉里程计法(Lidar-Monocular Visual Odometry, LIMO)<sup>[56]</sup>首先将点云投影到图像中,选定特征及周围固定范围内的点,进而提取平面。然后,使用固定宽度的深度直方图估计角和边特征的深度,使用基于透视投影的  $N$  点法(Perspective- $N$ -Point, PNP)进行帧间里程计运动估计。最后,使用语义信息滤除动态目标,使用 BA 对关键帧进行优化并估计自身运动。但此方法不适用于闭合环路,且激光雷达数据使用较少,其累积误差随路径增加而增加。

(2)LIV-LAM。激光雷达和视觉定位与建图法(LiDAR and Visual Localization and Mapping, LIV-

LAM)<sup>[57]</sup>将视觉目标检测与激光雷达里程计测量相结合,同时将闭环检测与姿态图优化相关联。在一定帧数中选择一个新的关键帧并提取尺度不变特征,反馈至聚类模块中。该方法在激光雷达里程计中提取边缘和平面特征,使用基于视觉的特征学习法进行特征对齐与融合,进行位姿变换后加入点云图中。

(3)DVL-SLAM。直接视觉激光同时定位与建图法(Direct Visual LiDAR SLAM, DVL-SLAM)<sup>[58-59]</sup>直接将激光雷达测得的深度信息应用于视觉 SLAM 中,使用迭代法将误差最小化。在位姿图优化过程中,边缘化开始帧并加入位置识别以关闭循环。此方法适用于低分辨率相机和稀疏激光雷达融合的情况。

此外 Pilatus<sup>[60]</sup>的研究中无人驾驶感知部分使用了 2 个激光雷达和 2 个单目相机,旨在检测长距离轨道边界。通过融合传感器原始数据求得汽车纵横向及旋转速度。视觉模块使用卷积神经网络估计边界距离,将检测目标映射到三维空间。使用基于图优化的 SLAM 算法实时建立全局地图,使用非线性最小二乘法估计自身姿态。该方法虽能应对某些复杂环境,但其成本高、实用性差。齐继超等<sup>[61]</sup>将单目相机与激光雷达进行融合,针对不同深度信息的特征点采用不同的位姿估计策略,降低了位姿估计误差。李振拯等<sup>[62]</sup>使用普通帧与关键帧进行匹配建立局部地图,并采用迭代法最小化残差,保证了后端非线性优化的计算要求,降低了特征关联的误差。在进行状态估计时融合关键帧、IMU 和回环检测的数据,使得误差最小,使得定位和建图更精确。

综上所述,多传感器融合的基础理论研究已较为成熟,但将理论成果转化为实际应用仍面临较大挑战,仍需更完善的技术来提高算法的可靠性。在 SLAM 技术领域,传统方法在恶劣环境条件下(如雨雪天气、光照剧烈变化、动态障碍物多等)对环境信息置信度低。深度学习虽然能在一定程度上改善上述情况但其应用还需进一步研究。传感器数据类型差异与时间不同步、动态和复杂环境中信息置信度低、数据处理和保留周期以及建图实时性等是目前研究需攻克的技术难点。

## 3.3 多传感器融合存在的问题与建议

本节将针对多传感器融合的 SLAM 技术在实际应用中存在的问题提出相应解决思路和建议。

### 3.3.1 数据类型及结构差异

不同的传感器输出的数据格式及时间存在差异,这要求在融合处理过程中采取较高的技术标准。在数

据处理中,需将表示同一时刻同一物体的数据进行关联,并对数据进行补偿,尽可能全面地描述当前环境。在SLAM系统中,数据处理精度与建图质量呈正相关。

### 3.3.2 累积误差

在SLAM系统中,累积误差主要包括里程计误差、数据关联误差和测量误差<sup>[63]</sup>。里程计通过积分方式获得数据,其随着时间累积增加。测量误差受传感器和环境因素影响,同时影响数据关联误差。累积误差影响建图精度和主体定位准确度。降低累积误差的方法包括缩短积分周期、提高传感器测量精度以及通过提升数据关联算法提高匹配精度。

### 3.3.3 适应性差

目前研究大多针对特定平台和环境,导致系统框架的适应性受限。为了提高模型适应性,可以采用不依赖于传感器的数据处理方法,并引入学习模块,将SLAM技术与深度学习进行融合,利用深度学习的适应性和学习能力,提升SLAM技术的延展性<sup>[46]</sup>,使其在各种环境中能够有效地提取环境特征。以下为3种融合深度学习的思路:(1)在特征匹配、位姿估计或优化过程中融入深度学习;(2)将深度学习获得的信息与SLAM的地图信息进行融合;(3)对点云信息进行标签化处理。

### 3.3.4 传感器获取信息有限

在SLAM中运用的传感器主要有相机、激光雷达、毫米波雷达、惯性测量单元以及轮速里程计,但目前上述传感器均存在性能缺陷。建议研究新型传感器,融合现存传感器优势,获取高质量且处理需求低的数据。例如,激光雷达和相机的优势进行融合成为一种新型传感器,可规避不同传感器数据类型和采样频率不同的问题。

### 3.3.5 地图类型

在不同场景下建立特定类型的地图,以及确保地图的更新速率,是未来需要进一步研究的问题。需根据内存和算力,结合不同地图的优劣势、权衡精度和实时性建立和更新地图。

## 4 未来的研究方向

多传感器融合仍然是未来主流的研究方向。然而,需要对融合方法、融合位置以及融合数据类型的选择进行深入研究,从而获得更好的研究成果。

### 4.1 深度学习与传统方法相互融合方案

在实际中,模型的计算速度和准确性均具有重要意义,平衡二者将是未来研究的重点和难点。高分辨率图像和大规模点云的处理对现有移动计算平台提

出了较高要求,可能导致掉帧、高功耗和可靠性降低。对于掉帧问题,可以通过多段数据拟合<sup>[64]</sup>、序列预测<sup>[65]</sup>等方法填充图像和点云。研究表明<sup>[66-67]</sup>,深度学习可以通过减少输入(如点云、像素、体素)的数量或网格深度降低计算成本。同时,基于点云和基于图像的融合方法相比于基于体素的融合方法更具延展性。

### 4.2 摄像头和激光雷达融合方案

从研究现状看来,摄像头和激光雷达可以实现优势互补,但冗余性对自动驾驶汽车安全行驶至关重要。缺乏冗余设计的系统,在信号路径失效时,整体性能将显著下降。为了提高冗余性,可以将不同传感器输入同一模块并进行融合,或采用多数据的多路径融合,从而提高系统在某一信号失效情况下的精度。

### 4.3 信息丢失和错位的改善方案

多传感器融合模型在整合不同传感器数据时,由于各传感器内在和外特性的差异,存在信息丢失和错位问题<sup>[68-69]</sup>。在各传感器信息匹配过程中,一方面可以设定严格的对应关系<sup>[70-71]</sup>,另一方面可以利用周围信息作为补充<sup>[72]</sup>,提高匹配的性能。考虑到三维信息比二维信息更丰富,未来研究应倾向于采用升维融合策略,将低维信息投影到高维信息中,充分利用原始数据,减少信息丢失量。

目前,数据融合通常采用串联和元素乘法<sup>[73]</sup>,但其直接且简单的操作无法融合较大差异的数据。未来研究可以探索更丰富的融合级联结构,或采用双线性映射机制进行特征融合,从而提高融合性能。

### 4.4 针对角落及边缘和对抗性攻击可能的方向

自动驾驶汽车多在不可预测的开放环境中运行,因此其判断不常见的障碍物、角落和边缘地去的能力具有重要意义。例如,车辆转弯或在道路狭窄的地方行驶时,摄像头和激光雷达的处理能力受限。因此,可以利用多传感器来感知周围环境,发挥多种传感器优势,进一步提高安全性。对抗性攻击通过发送具有干扰性的数据导致计算机判断错误,对自动驾驶汽车的安全性构成威胁。为提高安全性,可结合三维立体几何与图像进行共同判定,以提升判断准确率。

## 5 结束语

本文详细阐述了多传感器融合在自动驾驶汽车SLAM领域相关研究成果,从不同的融合方法分析了其研究现状,归纳了目前研究的难点和重点并提出建议。在无人驾驶研究领域,通过紧耦合或松耦合的方

式分析并融合视觉、激光雷达、IMU等传感器数据,可以实现传感器之间的优势互补,提高系统的可靠性和准确性。此外,SLAM技术在自动驾驶汽车领域具有较大应用前景,如感知环境、车辆导航等方面。多传感器融合SLAM技术可以实现高精度的定位与建图,给车辆提供实时的路径规划。

本文主要研究了SLAM技术在无人驾驶领域的运用,未来的研究可以扩展至机器人导航、AR和VR等领域。同时,后续研究应考虑环境适应性、实时性、准确性、语义理解及信息融合的挑战,以进一步推进多传感器融合SLAM技术的发展和运用。

#### 参 考 文 献

- [1] 李曦. 人工智能技术在智慧交通领域的应用分析[J]. 中国公路, 2020(15): 94-95.
- [2] 冯黎, 郭承军. 基于GNSS/SINS/双目视觉里程计的车载导航系统分析与设计[J]. 汽车技术, 2019(10): 37-41.
- [3] 宋佳昕. 移动机器人室外大尺度场景定位及语义建图算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2019.
- [4] KAESS, MICHAEL R, ANANTH D, et al. ISAM: Incremental Smoothing and Mapping[J]. IEEE Transactions on Robotics, 2008(6): 1365-1378.
- [5] KAESS, MICHAEL J, HORDUR R, et al. ISAM2: Incremental Smoothing and Mapping Using the Bayes Tree[J]. The International Journal of Robotics Research, 2012(2): 216-235.
- [6] QIN T, LI P L, SHEN S J. VINS-Mono: a Robust and Versatile Monocular Visual-Inertial State Estimator[J]. IEEE Transactions on Robotics, 2018(4): 1004-1020.
- [7] QIN T, PAN J, CAO S Z, et al. A General Optimization-based Framework for Local Odometry Estimation with Multiple Sensors[J]. arXiv, 2019.
- [8] LIU H M, ZHANG G F, BAO H J. Robust Keyframe-based Monocular SLAM for Augmented Reality[J]. 2016 IEEE International Symposium on Mixed and Augmented Reality (ISMAR-Adjunct), 2016, 340-341.
- [9] LIU Y B, JUN M. RDS-SLAM: Real-Time Dynamic SLAM Using Semantic Segmentation Methods[J]. IEEE Access, 2021, 9: 23772-23785.
- [10] 朱雅萌. 基于固态3D激光雷达的SLAM技术研究[D]. 北京: 北方工业大学, 2022.
- [11] 徐军. 基于多传感器融合的移动机器人同步定位与建图研究[D]. 镇江: 江苏科技大学, 2020.
- [12] 高翔, 张涛. 视觉十四讲: 从理论到实践[M]. 电子工业出版社, 2019.
- [13] 高塞航. 多传感器融合的SLAM设计与实现[D]. 长春: 吉林大学, 2022.
- [14] GILMORE R. Baker-Campbell-Hausdorff Formulas [J]. Journal of Mathematical Physics, 1974(12): 2090-2092.
- [15] WANG G, WEI Y, QIAO S, et al. Generalized Inverses: Theory and Computations[M]. Springer, 2018.
- [16] WANG Y. Gauss-Newton Method[J]. Wiley Interdisciplinary Reviews: Computational Statistics, 2012(4): 415-20.
- [17] MORÉ J J. The Levenberg-Marquardt Algorithm: Implementation and Theory [M]. Berlin: Springer, 1978.
- [18] 高兴波, 史旭华, 葛群峰, 等. 面向动态物体场景的视觉SLAM综述[J]. 机器人, 2021(6): 733-750.
- [19] 苏欣, 梁林林. 基于单目摄像头的测距方法、车载测距设备以及存储介质: CN202111628201.2[P]. 2022-04-08.
- [20] MAURO D C, Taihú P, FEDERICO B. DS-PTAM: Distributed Stereo Parallel Tracking and Mapping SLAM System[J]. Journal of Intelligent & Robotic Systems, 2019(2): 365-377.
- [21] ZHOU Y, GUILLERMO G, SHEN S J. Event-based Stereo Visual Odometry[J]. IEEE Transactions on Robotics, 2021(5): 1433-1450.
- [22] ANTONI R V, HENRI R, TIMO H, et al. Ultimate SLAM? Combining Events, Images, and IMU for Robust Visual SLAM in HDR and High-Speed Scenarios[J]. IEEE Robotics and Automation Letters, 2018(2): 994-1001.
- [23] 王海, 李洋, 蔡英凤, 等. 基于激光雷达的3D实时车辆跟踪[J]. 汽车工程, 2021(7): 1013-1021.
- [24] HONG Z Y, PETILLOT Y, WANG S. RadarSLAM: Radar Based Large-Scale SLAM in All Weathers[J]. arXiv, 2020.
- [25] EUGIN H, YOUNG-SEOK J, JONG-HUN L. Moving and Stationary Target Detection Scheme Using Coherent Integration and Subtraction for Automotive FMCW Radar Systems[J]. IEEE Radar Conference, 2017(8): 0476-0481.
- [26] ROBERT P, GANG L, CHRISTIAN S, et al. Semantic Segmentation on Automotive Radar Maps[J]. IEEE Intelligent Vehicles Symposium, 2019(9):756-763
- [27] HEEMANG S, HYUN-CHOO S. Classification and Spectral Mapping of Stationary and Moving Objects in Road Environments Using FMCW Radar[J]. IEEE Access, 2020(8): 22955-22963.
- [28] FRANK S, CHRISTOPH G K, MATTHIAS R, et al. Landmark Based Radar SLAM Using Graph Optimization[J]. 2016 IEEE 19th International Conference on Intelligent Transportation Systems, 2016: 2559-2564.
- [29] 司马健. 一种基于惯性测量的管线测绘仪的设计与实

- 现[D]. 东南大学, 2018.
- [30] LIU Y Q, YANG D D, LI J M, et al. Stereo Visual-Inertial SLAM With Points and Lines[J]. IEEE Access, 2018(6): 69381-69392.
- [31] 何成诚. 多传感器融合的无人车SLAM定位方法研究[D]. 重庆理工大学, 2022.
- [32] CHGHAF M, RODRIGUEZ S, OUARDI A E. Camera, Lidar and Multi-Modal SLAM Systems for Autonomous Ground Vehicles: a Survey[J]. Journal of Intelligent and Robotic Systems: Theory and Applications, 2022(1): 1-35.
- [33] 王永胜, 罗禹贡, 黄晨, 等. 基于拓扑地图的自主泊车路径协调与优化策略[J]. 中国公路学报, 2021(1): 177-187.
- [34] 王飞, 王耀力. 基于ORB-SLAM2的三维占据网格地图的实时构建[J]. 科学技术与工程, 2020(1): 239-245.
- [35] 马腾, 杨晟, 朱晓玲. 用于构建基于地标的高清地图的系统和方法: CN201880092936.8[P]. 2020-12-25.
- [36] 李帅鑫, 李九人, 田滨, 等. 面向点云退化的隧道环境的无人车激光SLAM方法[J]. 测绘学报, 2021, 50(11): 1487-1499.
- [37] 蒋林, 刘奇, 雷斌, 等. 激光与视觉融合识别并构建语义地图改善定位性能[J]. 中国激光, 2022(18): 134-148.
- [38] DINH V N, KIM G. Solid-State Lidar Based-SLAM: a Concise Review and Application[J]. 2021 IEEE International Conference on Big Data and Smart Computing, 2021: 302-305.
- [39] 聂文康, 蒋林, 雷斌, 等. 基于深度学习的语义栅格地图构建方法[J]. 武汉科技大学学报, 2021(6): 468-477.
- [40] HUANG K L, SHI B T, LI X, et al. Multi-Modal Sensor Fusion for Auto Driving Perception: a Survey[J]. arXiv, 2022.
- [41] LU P, DAI F Z. An Overview of Multi-Sensor Information Fusion[J]. 2021 6th International Conference on Intelligent Informatics and Biomedical Sciences, 2021(6): 5-9.
- [42] 鹿瑶, 张佳琦, 赵旺. 一种新的混合式数据融合方法及其在雷达组网中的应用[J]. 现代导航, 2020(4): 277-282.
- [43] 钱伟, 常霞, 虎玲. 多传感器图像融合质量评价方法研究[J]. 计算机时代, 2018(4): 1-3.
- [44] FEDERICO C. A Review of Data Fusion Techniques[J]. Scientific World Journal, 2013(2013): 704504-704522.
- [45] XU X B, ZHAGN L, YANG J, et al. A Review of Multi-Sensor Fusion SLAM Systems Based on 3D Lidar[J]. Remote Sensing, 2022(12).
- [46] CUI Y D, CHEN R, CHU W B, et al. Deep Learning for Image and Point Cloud Fusion in Autonomous Driving: a Review[J]. IEEE Transactions on Intelligent Transportation Systems, 2022(2): 722-739.
- [47] NEWMAN P, COLE D, HO K. Outdoor SLAM Using Visual Appearance and Laser Ranging[J]. Proceedings 2006 IEEE International Conference on Robotics and Automation, 2006: 1180-1187.
- [48] 初宏伟, 张颖. 自动驾驶汽车状态估计的矩阵加权自适应扩展卡尔曼滤波方法[J]. 汽车技术, 2022(5): 50-55.
- [49] SHAO W Z, VIJAYARANGAN, SRINIVASAN, LI C, et al. Stereo Visual Inertial Lidar, Simultaneous Localization and Mapping[J]. arXiv, 2019.
- [50] JIANG G L, YIN L, JIN S K, et al. A Simultaneous Localization and Mapping(SLAM) Framework for 2.5D Map Building Based on Low-Cost Lidar and Vision Fusion[J]. Appl, 2019(10): 2105.
- [51] SEO Y, CHOU C. A Tight Coupling of Vision-Lidar Measurements for an Effective Odometry[J]. 2019 IEEE Intelligent Vehicles Symposium, 2019: 1118-1123.
- [52] ZUO X X, GENEVA P, LEE W, et al. LIC-Fusion: Lidar-Inertial-Camera Odometry[J]. arXiv, 2019.
- [53] ZUO X X, YANG Y L, Geneva Patrick, et al. LIC-Fusion 2.0: Lidar-Inertial-Camera Odometry with Sliding-Window Plane-Feature Tracking[J]. arXiv, 2020.
- [54] LIN J R, ZHENG C R, XU W, et al. R2LIVE: A Robust, Real-Time, Lidar-Inertial-Visual Tightly-Coupled State Estimator and Mapping[J]. IEEE Robotics and Automation Letters, 2021(4): 7469-7476.
- [55] 蔡英凤, 陆子恒, 李祎承, 等. 基于多传感器融合的紧耦合SLAM系统[J]. 汽车工程, 2022(3): 350-361.
- [56] JOHANNES G, ALEXANDER W, MARTIN L. LIMO: Lidar-Monocular Visual Odometry[J]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2018: 7872-7879.
- [57] REZA R, WANG Z Y, VISHNU S C, et al. LIV-LAM: Lidar and Visual Localization and Mapping[J]. 2020 American Control Conference, 2020: 659-664.
- [58] SHIN Y, PARK Y S, KIM A. Direct Visual SLAM Using Sparse Depth for Camera-Lidar System[J]. 2018 IEEE International Conference on Robotics and Automation, 2018: 5144 - 5151.
- [59] SHIN Y, PARK Y S, KIM A. DVL-SLAM: Sparse Depth Enhanced Direct Visual-Lidar SLAM[J]. Autonomous Robots, 2020, 44(2): 115 - 130.
- [60] LEIV A, ADRIAN B, ALEX H, et al. Accurate Mapping and Planning for Autonomous Racing[J]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 4743-4749.
- [61] 齐继超, 何丽, 袁亮, 等. 基于单目相机与激光雷达融合

- 的SLAM方法[J]. 电光与控制, 2022(2): 99-102+112.
- [62] 李振拯, 丁恩杰, 王戈琛. 基于LiDAR-IMU松耦合的同时定位与建图方法[J]. 传感器与微系统, 2022(4): 36-39+43.
- [63] 吴建清, 宋修广. 同步定位与建图技术发展综述[J]. 山东大学学报(工学版), 2021(5): 16-31.
- [64] IMRE E, GUILLEMAUT J, HILTON A. Through-the-Lens Multi-Camera Synchronisation and Frame-Drop Detection for 3D Reconstruction[J]. 2012 Second International Conference on 3D Imaging, 2012: 395-402.
- [65] LI Y P, ROBLEK D, TAGLIASACCHI M. From Here to There: Video Inbetweening Using Direct 3D Convolutions[J]. arXiv, 2019.
- [66] WU Z R, SONG S R, ADITYA K, et al. 3D ShapeNets: a Deep Representation for Volumetric Shapes[J]. 2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015(6): 1912-1920.
- [67] THOMAS H, QI C R, DESCHAUD J, et al. KPConv: Flexible and Deformable Convolution for Point Clouds[J]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 6410-6419.
- [68] SHIN K, KWON Y P, TOMIZUKA M. Roarnet: a Robust 3D Object Detection Based on Region Approximation Refinement[J]. 2019 IEEE Intelligent Vehicles Symposium, 2019(11): 2510-2515.
- [69] CHEN Y Q, LIU F, PEI K. Cross-Modal Matching CNN for Autonomous Driving Sensor Data Monitoring[J]. 2021 IEEE/CVF International Conference on Computer Vision Workshops, 2021: 3103-3112.
- [70] MEYER G P, CHARLAND J, HEGDE D, et al. Sensor Fusion for Joint 3D Object Detection and Semantic Segmentation[J]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2019: 1230-1237.
- [71] MAHMOUD A, WASLANDER S L. Sequential Fusion Via Bounding Box and Motion Pointpainting for 3D Object Detection[J]. 2021 18th Conference on Robots and Vision, 2021(3): 9-16.
- [72] XIE L, XIANG C, YU Z X, et al. PI-RCNN: an Efficient Multi-Sensor 3D Object Detector with Point-Based Attentive Cont-Conv Fusion Module[J]. In Proceedings of the AAAI Conference on Artificial Intelligence, 2020(34): 12460-12467.
- [73] WANG C W, MA C, ZHU M, et al. Pointaugmenting: Cross-Modal Augmentation for 3D Object Detection[J]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021(11): 11794-11803.

(责任编辑 梵玲)

## 《汽车工程师》征稿启事

《汽车工程师》于1974年创刊,是由中国第一汽车集团有限公司主管、中国第一汽车股份有限公司主办的国内外公开发行的汽车应用技术类学术期刊,为RCCSE中国准核心期刊、CACJ中国应用型扩展期刊,被哥白尼精选数据库、EBSCO学术数据库、欧洲学术出版中心(EuroPub)数据库、J-Gate数据库收录。

《汽车工程师》以报道汽车产品设计领域的技术研究成果为主,专注于技术开发与应用层面的创新成果,提供汽车设计创新解决方案。《汽车工程师》将把握电动化、智能化、网联化、共享化的汽车技术主流发展趋势,努力吸收优质稿源,为我国汽车工程技术创新能力提升贡献力量。重点征稿方向包括:锂离子电池与新体系电池、动力电池热管理与热失控、燃料电池及其关键零部件、车用电机及其控制器、自动驾驶汽车环境感知与感知融合、自动驾驶汽车定位与建图、自动驾驶汽车测试、人工驾驶-无人驾驶车辆混行条件下的自动驾驶控制、智能线控底盘、一体化底盘、功能安全和预期功能安全。

热忱欢迎汽车行业的专家学者不吝赐稿,反映国家重点扶持项目、自然科学基金项目和其他重点项目等研究成果的稿件将优先发表,我们期待与您共同践行“把论文写在祖国大地上”的指示精神,为强大中国汽车工业作贡献!

本刊使用协同采编系统处理稿件,请登陆期刊网站注册后投稿,投稿要求见本刊网站中“下载中心”栏目的作者指南,网址:<http://tjqc.cbpt.cnki.net>。

《汽车工程师》编辑部