

基于因子图的自动驾驶融合定位研究

袁子叶, 尹慧琳, 伍淑莉

(同济大学 中德学院 电子信息系, 上海 201804)

摘要: 在自动驾驶系统的即时定位及地图构建问题中, 当行车路况复杂多变时, 如何对车辆位姿进行准确实时估计是一个关键问题。就该问题提出基于因子图的多传感器融合方法, 在 Matlab 软件环境中实现车辆的准确实时定位。根据实际驾驶过程的特性选择试验采用的数据类型并建立相应的数学模型, 分别根据 GPS 及 IMU 数据特征以及 VO 和 IMU 的数据特征建立相应的融合因子图模型, 基于 KITTI 数据集, 对所建立的融合因子图模型进行试验验证。结果表明, 通过融合因子图模型可以准确地估计车辆当前时刻的位姿。

关键词: 自动驾驶系统; 即时定位及地图构建; 信息融合; 因子图

中图分类号: TP181

文献标识码: A

DOI: 10.3969/j.issn.2095-1469.2019.04.02

Research on Fusion Localization of Automated Driving Systems Based on Factor Graph

YUAN Ziye, YIN Huilin, WU Shuli

(Department of Electronics and Information, CDHK, Tongji University, Shanghai 201804, China)

Abstract: For the localization and map construction of automated driving systems, the key issue is to accurately estimate the vehicle pose for decision-making when the road conditions are complicated. This paper proposes a multi-sensor fusion method based on factor graph to achieve the accurate real-time localization of the vehicle by using Matlab. Initially, the data type used in the experiment was selected and the corresponding mathematical model was established. Next, the fusion factor graph model was established by fusing the VO and IMU data or by fusing the GPS and IMU data. Finally, the experimental verification of the model was carried out based on the KITTI dataset. The results show that the position and posture of the vehicle can be accurately estimated by the factor graph model.

Keywords: automated driving system; simultaneous localization and mapping; data fusion; factor graph

自动驾驶技术在降低交通事故发生率、缓解交通拥堵、实时提供有效最短路径等方面起到了明显

的作用^[1], 其中的关键技术“即时定位与地图构建”(Simultaneous Localization and Mapping, SLAM)

收稿日期: 2019-01-16 改稿日期: 2019-03-07

基金项目: 国家自然科学基金(61701348); 国家重点研发计划项目(2016YFB0100900)

参考文献引用格式:

袁子叶, 尹慧琳, 伍淑莉. 基于因子图的自动驾驶融合定位研究[J]. 汽车工程学报, 2019, 9(4): 243-251.

YUAN Ziye, YIN Huilin, WU Shuli. Research on Fusion Localization of Automated Driving Systems Based on Factor Graph [J]. Chinese Journal of Automotive Engineering, 2019, 9(4): 243-251. (in Chinese)

也随之备受关注。在 SLAM 中, 能够根据多个传感器信息, 对车辆进行精确定位尤为重要, 所以提高即时定位的精确度一直是研究的热点^[2]。

对于车辆定位有许多不同的方法, 其中利用全球定位系统 (Global Positioning System, GPS) 与惯性测量元件 (Inertial Measurement Unit, IMU) 进行数据融合从而对车辆定位, 是最常用的方法之一^[3]。GPS 的定位精确度高, 且时间以及地域限制对其精度影响较小, 但当车辆在有地形遮蔽处驾驶时, GPS 信号有可能中断, 如隧道、深山等^[4]。IMU 能以较高的频率提供多种高精度的导航参数, 如速度、加速度、角速度、角加速度等, 但由于其数据本身存在噪声干扰, 导致位置误差会随时间累计而产生较大偏差, 不适合长时间高精度实时定位^[5]。然而, 由于 GPS 数据与 IMU 数据具有互补性, 所以可通过数据融合实现高精度的实时定位^[6]。同 GPS 和 IMU 数据融合类似的, 还有视觉里程计 (Visual Odometry, VO) 与 IMU 的数据融合。VO 主要利用车载相机连续拍摄图片, 通过图片中多个明显的特征点与相机的距离对相机进行定位, 进而确定车辆位置^[7], 但在使用 VO 定位时, 需要提前标定行车地点周围的路标, 即照片中的特征点。所以, 相对于 GPS 定位, VO 需要做大量的前期工作才能确保定位的可靠性^[8]。也正是由于 VO 需要多个路标点, 在对相机定位的同时, 可以对陆标点位置进行优化, 所以常用于 SLAM 中的地图构建。

在处理数据融合问题时, 主要使用的方法有加权平均法、卡尔曼滤波法、贝叶斯网络法等^[9]。其中, 加权平均法模型比较简单, 但对于数据类型不同、更新频率不同、噪声模型也不同的多组传感器来说, 融合效果并不理想。卡尔曼滤波是最常用的滤波算法, 现在许多优化问题都选择采用卡尔曼滤波法解决^[10]。卡尔曼滤波是一种利用线性系统状态方程, 通过系统输入输出观测数据, 对系统状态进行最优估计的算法。卡尔曼滤波非常适合于连续系统, 只需要保存当前状态与前一步状态即可。并且, 卡尔曼滤波占用内存较小, 处理速度快, 适合应用于实时系统^[11]。但卡尔曼滤波必须已知系统状态方程以

及测量方程, 并且要求状态方程与测量方程为线性方程, 如果方程为非线性, 则要先对其进行线性化, 才可以使用卡尔曼滤波, 但线性化过程本身就导致了误差的产生^[12]。贝叶斯网络法是新兴的优化方法, 其主要思想是由先验概率以及样本信息得到后验概率, 最后由最大后验估计方法对数据进行优化^[13]。贝叶斯网络能以有向无环图的形式直观地反映出多组传感器测量值与车辆位置之间的因果关系, 在不同的传感器组测量坐标一致时, 可以直接对传感器数据进行融合^[14], 但在计算过程中, 发现很多状态之间的关系与所求状态无关, 在状态数量过多的情况下采用贝叶斯网络计算将会产生庞大的计算量。同时, 当在贝叶斯网络中新增节点时, 往往需要对全图进行更新, 也增加了优化过程的工作量, 不适合用于实时系统。

针对上述问题, 考虑到实际应用的准确性和实时性, 本文提出采用因子图进行数据融合的方法。因子图同贝叶斯网络一样, 也是概率图的一种, 它是由 KSCHISCHANG 等^[15]在 2001 年提出的一种二部无向图。因子图可以将一个具有多变量的全局函数分解为几个局部函数的乘积, 即在计算过程中可以分离出与当前关系无关的变量^[16]。同时, 由于因子图与 SLAM 底层的优化有更紧密的联系, 所以选择用因子图模型进行 SLAM 的优化。相比于卡尔曼滤波法和贝叶斯网络法, 因子图更直观地表现了不同节点之间的关系。在需要添加状态量时, 因子图可以直接在原有图的基础上增添因子, 同样, 如果测量值可信度较低, 或信号丢失, 只需要在原图的基础上简单地减少因子即可, 不需要特别地编程或者修改模型。因子图的这一特点极大地减少了处理 SLAM 问题时的计算量^[17]。

1 建立因子图模型

因子图是概率图的一种, 其中有两类节点, 分别是变量节点与因子节点。本文把车辆位姿、路标位置、传感器测量值等作为变量节点, 测量值与位姿之间的概率关系等作为因子节点, 建立因子图模型。

1.1 因子图模型介绍

假设在运行的车辆上装备有多种传感器，包括IMU、单目或立体照相机、激光雷达、GPS等。首先，构建因子图中的变量节点，用 x_i 表示 t_i 时刻的车辆位姿，包括位置、速度、方向，用 c_i 表示 t_i 时刻的标准参数，包括加速度计和陀螺仪的偏差、照相机角度偏差和位置偏差等。此后，可以定义从 t_1 时刻到当前时刻 t_k 所产生的所有状态为：

$$X_k = \{x_i\}_{i=1}^k, \quad C_k = \{c_i\}_{i=1}^k. \quad (1)$$

在有观测地标时，定义第 j 个观测地标为 l_j 。类似式(1)，可以定义从 t_1 时刻到当前时刻 t_k 产生的所有观测地标为 L_k ，则有：

$$L_k = \{l_i\}_{i=1}^k. \quad (2)$$

从 t_1 到 t_k 时刻，所有的状态变量可以表示为：

$$V_k = \{X_k, C_k, L_k\}. \quad (3)$$

同时，将从 t_1 时刻开始接收到的所有的传感器数据记为 Z_k ，则相应的有：

$$Z_k = \{z_i\}_{i=1}^k. \quad (4)$$

式中： z_i 表示在 t_i 时刻接收到的测量值。

构建完所有变量节点之后，开始构建因子节点，因子节点主要描述了变量之间的概率关系。由上述定义得到，当前时刻 t_k 的位姿状态 V_k 与前一时刻 t_{k-1} 的状态 V_{k-1} 有关，也与 t_k 时刻的标准参数 c_k 有关，同时 c_k 也由前一时刻的 c_{k-1} 决定，由递推关系以及全概率公式，可以把由观测值 Z_k 得到实际位姿 V_k 的联合概率函数表示为：

$$p(V_k | Z_k) = p(V_0) \prod_{i=1}^k \left[p(x_i | x_{i-1}, c_{i-1}, z_{i-1}) \times p(c_i | c_{i-1}) \prod_{z_j \in Z_i \setminus z_i} p(z_j | v_i^j) \right]. \quad (5)$$

式中： p 为联合概率函数。

则由联合概率密度函数得到的最大后验估计值 V_k^* 为：

$$V_k^* = \arg \max_{V_k} p(V_k | Z_k). \quad (6)$$

由式(5)可以看出，联合概率密度函数是非常复杂的，但在实际情况中，当前时刻 t_k 的位姿状

态 V_k 与前一时刻 t_{k-1} 的状态 V_{k-1} 、当前时刻 t_k 的测量值 Z_k 以及标准参数 c_k 有关，即有：

$$V_k = h(V_{k-1}, c_k, Z_k). \quad (7)$$

$$c_k = g(c_{k-1}). \quad (8)$$

式中： g 为由前一时刻 t_{k-1} 的标准参数 c_{k-1} 到当前时刻 t_k 的标准参数 c_k 的状态转移方程。

则式(6)中的 $p(V_k | Z_k)$ 可认为与多组误差方程的乘积成正比，即：

$$p(V_k | Z_k) \propto \prod_i f_i(V_k^i). \quad (9)$$

式中： f_i 为第 i 组数据的误差方程，在因子图中， f_i 为变量节点之间的因子节点。

当噪声为高斯白噪声时，有：

$$f_i = \exp \left[-\frac{1}{2} \left\| h_i(V_k^i) - z_i \right\|_{\Sigma_i}^2 \right]. \quad (10)$$

式(7)可简单表示为：

$$f_i = d[\text{err}_i(V_k^i, z_i)]. \quad (11)$$

在构建完所有的变量节点 V_i 与因子节点 f_i 之后，建立完整的因子图模型如图1所示。




图1 行车路径的因子图模型

在图1中，红色节点代表由IMU测量值表示的变量节点，该变量节点构成了链状骨架的主体，两侧的蓝色节点代表由路标位置表示的变量节点，该变量节点是骨架两侧的蓝色线段所代表的二元似然因子，即因子节点，与红色节点相连^[18]。

1.2 建立GPS及IMU融合因子图模型

IMU与GPS的数据更新频率不同，IMU相对更新频率较高，具体的数据更新频率由不同的IMU传感器型号所决定。由于IMU更新较为频繁，考虑以IMU代表的变量因子作为骨架的主体，构建因子图如图2所示。




图 2 IMU 因子图模型

如图 2 所示, x_i 表示第 i 时刻车辆的状态, c_i 表示第 i 时刻的标准参数。由于 IMU 数据会随时间产生误差累积, 该误差产生的原因除了测量噪声以外, 还有 IMU 传感器自身产生的漂移误差, 所以需要添加变量节点 c_i 对 IMU 传感器的测量值进行矫正。 f^{Prior} 是一元因子, 该因子由式 (5) 中的 $p(V_0)$ 确定, 只和第一步状态 x_1 有关。状态 x_{i+1} 由 x_i 和 c_i 以及当前时刻测量值 z_i 所确定, 因子节点 f^{IMU} 如式 (10) 所示, 其中的 $h_i(V_k^i)$ 为由状态 x_i 和 c_i 到下一状态的状态转移方程^[14]。与此类似, 因子节点 f^{bias} 由式 (8) 确定, 为 c_i 到 c_{i+1} 的转移方

程。在实际应用中, 可以适当降低标准参数的更新频率, 如图 3 所示。

骨架构建完成后, 为了提高定位的精确度, 将 GPS 数据与 IMU 数据进行融合。在每过一定步长 n 时, 添加因子节点 f^{GPS} 。其中间隔的步长 n 由车辆实际装备的 IMU 和 GPS 的更新频率决定。添加因子节点后的因子图如图 4 所示。

如图 4 所示, 在每个连接了因子节点 f^{GPS} 的变量节点 x_i 之间, 存在多个仅由 IMU 数据得到的车辆位姿。考虑将图 4 中间隔的步长中的变量节点合并, 对因子图化简的结果如图 5 所示。




图 3 减少参数后的 IMU 因子图模型




图 4 GPS 及 IMU 融合因子图模型




图 5 化简后的 GPS 及 IMU 融合因子图模型

在图 5 中, 状态 x_{i+1} 和 x_i 之间实际间隔了 $n \Delta t$, 图中的二元因子节点 f^{Equiv} 与 f^{IMU} 类似, 但是其中的 $h_i(V_k^i)$ 为第 t_i 时刻到 t_{i+n} 时刻的状态转移方程。

1.3 建立 VO 与 IMU 融合因子图模型

随着图像识别技术的发展, 利用照片或视频对行车附近的特征点进行标识的技术也日益成熟。反

之, 如果知道被标识的特征点的具体位置, 则可以利用图像得到车辆与特征点间的距离, 估计出车辆的具体位置。VO 定位的方式与 GPS 不同, GPS 主要通过卫星进行定位, 得到的是车辆的全球坐标。利用卫星定位, 导致 GPS 信号受到空间磁场干扰、建筑物遮蔽等因素的影响, 最终导致在某些特定场所或特定时间定位的偏差较大。针对上述问题, 不妨考虑用 VO 代替 GPS。

相比于 GPS 信号, 利用 VO 定位需要有明显的路标作为图像特征, 通过对图像与图像或图像与地图之

间的特征描述进行匹配, 进而确定车辆的确切位置。当然, 由于图像特征的局部特性, 误匹配的情况还是广泛存在的。根据上文所述, 在图 2 的基础上, 添加路标节点作为变量节点, 建立的因子图如图 6 所示。

图 6 中添加了变量节点 l_i , 表示第 i 个路标。连接路标 l_j 与车辆位姿状态 x_i 之间的因子节点 f^{vision} 与因子节点 f^{IMU} 类似, 但 z_k 变为车辆位置与特征点距离的测量值。由图 6 可知, 利用 VO 也可以在定位的同时对路标位置进行优化, 从而构建车辆驾驶区域的地图。




图 6 VO 及 IMU 融合因子图模型

由于本文主要讨论在 SLAM 中的融合定位问题, 不考虑构建驾驶区域地图, 所以弱化路标在因子图中的作用, 仅考虑由路标得到的车辆当前位姿信息, 即添加因子节点 f^{VO} 。又由于 VO 与 IMU 的数据更新频率也会随具体车载装备而不同, 一般情况下, VO 的数据更新频率低于 IMU 数据更新频率。根据以上描述, 可更新因子图如图 7 所示。

与图 5 相同, 由于因子节点 f^{VO} 所跨越的所有变量节点均只由 IMU 数据优化得到, 所以考虑将图 7 中间的因子节点和变量节点相融合, 可得到的因子图如图 8 所示。

同样, 状态 x_{t+1} 和 x_t 之间实际间隔了 $n\Delta t$, 图 8 中的二元因子节点 f^{Equiv} 中的 $h_i(V_k^i)$ 为第 t_i 时刻到 t_{t+n} 时刻的状态转移方程。




图 7 弱化路标节点后的融合因子图模型




图 8 化简后的 VO 及 IMU 融合因子图模型

2 试验结果及分析

本部分试验测试的硬件环境为内存 8 GB, Intel Core i7-8750 处理器, 主频 2.2 GHz, 软件环境为 Matlab。试验数据采用 KITTI 数据集, KITTI 数据

集由德国卡尔斯鲁厄理工学院和丰田美国技术研究院联合创办,是目前国际上最大的自动驾驶场景下的计算机视觉算法测评数据集。试验主要采用右侧的彩色摄像机和 GPS 导航系统 OXTS 的数据, OXTS 数据同时包括 GPS 定位信息和 IMU 数据信息。摄像机位置和 OXTS 位置如图 9 所示。




图9 传感器位置及坐标系

图9中,红色所标位置为摄像机位置,其中 x 轴方向为车辆正右方, y 轴方向为车辆正下方, z 轴方向为车辆正前方。蓝色所标位置为GPS导航系统OXTS位置,其中 x 轴方向为车辆正前方, y 轴方向为车辆正左方, z 轴方向为车辆正上方。

2.1 GPS 及 IMU 定位

由于GPS数据与IMU数据均由GPS导航系统获取,所以本试验的GPS信号与IMU信号有相同的时间频率。首先,将GPS数据与IMU数据从所获取的OXTS数据中分离。其次,对GPS数据进行处理,将GPS数据由全球经纬坐标,变为地面坐标。最后,将处理后的GPS数据和IMU数据带入图5所示的因子图模型中,得到行车路径的优化结果。流程如图10所示。






图10 GPS及IMU定位


本试验主要根据数据的数量、复杂度等因素,选取了4组不同的KITTI数据集进行测试,4组数据集的数据量分别为76帧、108帧、269帧和313帧。测试顺序按照数据集中数据信息的数量,由少至多依次排列,测试结果如图11所示。




(a) 预估轨迹



(b) 预估轨迹



(c) 预估轨迹



(d) 预估轨迹

图11 GPS及IMU定位后的车辆位姿

图 11 分别展示了由 4 组数据得到的红色 GPS 定位路径、绿色的因子图融合后的定位路径以及蓝色的实际行车路径。由图可知，经因子图融合后的定位路径曲线相较于原本的 GPS 定位路径曲线，精度更高。在 4 组数据中，由图 11c 可以观察出第 3 组数据相较于其它数据有所不同。在第 3 组数据中，车辆在数据采集的初始阶段进行了长时间的转向操作。然而，GPS 并没有明确对当时的车辆位姿进行判断，仅给出了大致定位。但采用因子图对数据融合之后，得到了车辆驾驶过程中明确的车辆位姿。

由第 3 组数据中前 100 组数据得到的 GPS 定位路径与因子图融合后的路径如图 12 所示，其中 GPS 定位结果在点 (0, 0) 附近 $\pm 0.5 \text{ m}$ 的位置，并未做明确的移动路径标识。但是由因子图得到的定位结果，明确地表现出车辆经历的位姿。






图 12 车辆移动幅度较小时的位姿（预估轨迹）

GPS 路径与由因子图融合后的定位路径的具体误差情况如图 13 所示。


根据图 13 所示的车辆定位误差信息，得到定位误差的均值与均方差值见表 1。




(a)



(b)



(c)



(d)

图 13 车辆定位误差

表 1 车辆定位误差

数据量 / 组	GPS 误差均值 /m	GPS 误差均方差 /m ²	融合误差均值 /m	融合误差均方差 /m ²
76	1.46	1.26	0.51	0.27
108	2.67	2.43	0.72	0.19
269	4.13	4.41	0.56	0.23
313	1.97	4.72	0.43	0.26

由图 13 和表 1 可知，在第 1 组数据中，GPS 定位的误差由于数据较少，误差的均值和均方差相对较小。随着数据量的增大，GPS 定位误差均值上升趋势减缓，基本保持在 4 m 左右，没有明显的上升。经过因子图融合后，定位误差相较于 GPS 定位误差有明显减少，误差均值基本可以保持在 1 m 左右。

综上所述,由因子图对数据进行融合之后得到的车辆位姿更接近真实情况。

2.2 VO 及 IMU 定位

VO 及 IMU 数据融合的因子图结构与 GPS 和 IMU 数据融合的因子图结构在骨架部分是相似的,但不同之处在于,VO 数据受到前一时刻和当前时刻车辆位姿的共同影响, GPS 数据仅受到当前时刻测量位姿的影响。

具体流程如图 14 所示,首先由彩色摄像机拍摄得到的图像,提取车辆的位姿信息。其次,统一 VO 数据和 IMU 数据的时间戳。最后,将得到的 IMU 数据以及 VO 数据带入图 8 所示的因子图模型中,得到融合后的车辆位姿。本次试验选取了 3 组不同的数据进行测试,按照流程图得到的测试结果如图 15 所示。




图 14 VO 及 IMU 定位






图 15 VO 及 IMU 定位后的车辆位姿

3 结论

为了更精确地实现 SLAM 中的定位,本文提出了建立因子图模型的方法,解决了准确判别车辆位姿的问题,包括 GPS 与 IMU 数据的融合,以及 VO 与 IMU 数据的融合,这两部分分别利用不同的数据对车辆位姿进行判断。其中,第一部分得到了较为理想的车辆定位结果,第二部分车辆定位结果不太理想,主要原因在于单目 VO 对于距离缺乏准确判断,并且随着时间增加漂移误差累积较大。即由于 VO 数据的准确度偏低导致定位路径偏差较大,但仍可看出数据融合对车辆定位路径进行了一定的矫正。目前还需要提高 VO 数据的准确度,在这方面可以选择双目或多目 VO 数据,以期待得到理想的效果。

参考文献 (References)

- [1] MA Shangchang, ZANMA T, ISHIDA M. Automatic Driving System Using Identification of Switched Systems with Unknown Switch Points [J]. IEEJ Transactions on Electrical and Electronic Engineering, 2006, 1(4): 426–437.
- [2] MUR-ARTAL R, MONTIEL J, TARDOS J. ORB-SLAM: a Versatile and Accurate Monocular SLAM System [J]. IEEE Transactions on Robotics, 2015, 31(5): 1147–1163.
- [3] ZHAO Yanning, TOSHIYUKI Y, TAKAYUKI M. An Analysis on Older Driver's Driving Behavior by GPS Tracking Data: Road Selection, Left/Right Turn, and Driving Speed [J]. Journal of Traffic and Transportation Engineering (English Edition), 2018, 5(1): 56–65.
- [4] WING M G, EKLUND A, KELLOGG L D. Consumer-Grade Global Positioning System (GPS) Accuracy and Reliability [J]. Journal of Forestry, 2005, 103(4): 169–173.
- [5] DRAWIL N M, AMAR H M, BASIR O A. GPS Localization Accuracy Classification: a Context-Based Approach [J]. IEEE Transactions on Intelligent Transportation Systems, 2013, 14(1): 262–273.
- [6] CARON F, DUFLOS E, POMORSKI D, et al. GPS/IMU Data Fusion Using Multisensor Kalman Filtering: Introduction of Contextual Aspects [J]. Information Fusion, 2006, 7(2): 221–230.
- [7] ZENG Qingxi, FENG Yupeng, MA Shan. A Fast Monocular Visual Odometry Pose Estimation Method for Self-Driving Vehicles [J]. Journal of Hebei University of Science and Technology, 2017, 38(5): 438–444.
- [8] NISTER D, NARODITSKY O, BERGEN J. Visual Odometry for Ground Vehicle Applications [J]. Journal of Field Robotics, 2006, 23(1): 3–20.
- [9] 林旭, 罗志才. 位移和加速度融合的自适应多速率 Kalman 滤波方法 [J]. 地球物理学报, 2016, 59(5): 1608–1615.
LIN Xu, LUO Zhicai. A New Adaptive Multi-rate Kalman Filter for the Data Fusion of Displacement and Acceleration [J]. Chinese Journal of Geophysics-Chinese Edition, 2016, 59(5): 1608–1615. (in Chinese)
- [10] WIDODO R B, WADA C. Attitude Estimation Using Kalman Filtering: External Acceleration Compensation Considerations [J]. Journal of Sensors, 2016(10): 1–24.
- [11] KULIKOVA M V. Likelihood Gradient Evaluation Using Square-Root Covariance Filters [J]. IEEE Transactions on Automatic Control, 2009, 54(3): 646–651.
- [12] ELEFFENDI M A, JOHNSON C M. Application of Kalman Filter to Estimate Junction Temperature in IGBT Power Modules [J]. IEEE Transactions on Power Electronics, 2016, 31(2): 1576–1587.
- [13] HE Jian, BAI Shuang, WANG Xiaoyi. An Unobtrusive Fall Detection and Alerting System Based on Kalman Filter and Bayes Network Classifier [J]. Sensors, 2017, 17(6): 1393.
- [14] KAESSE M, JOHANNSSON H, ROBERTS R, et al. iSAM2: Incremental Smoothing and Mapping Using the Bayes Tree [J]. The International Journal of Robotics Research, 2012, 31(2): 216–235.
- [15] KSCHISCHANG F R, FREY B J, LOELIGER H A. Factor Graphs and the Sum-Product Algorithm [J]. IEEE Transactions on Information Theory, 2001, 47(2): 498–519.
- [16] INDELMAN V, WILIAMS S, KAESSE M, et al. Information Fusion in Navigation Systems via Factor Graph Based Incremental Smoothing [J]. Robotics and Autonomous Systems, 2013, 61(8): 721–738.
- [17] FORSTER C, CARLONE L, DELLAERT F, et al. On-Manifold Preintegration for Real-Time Visual-Inertial Odometry [J]. IEEE Transactions on Robotics, 2017, 33(1): 1–21.
- [18] DELLAERT F, KAESSE M. Factor Graphs for Robot Perception [M]. Boston: Now Foundations and Trends, 2017.

作者介绍



责任作者: 袁子叶 (1994–), 女, 陕西西安人。硕士研究生, 主要从事自动驾驶、机器学习等方面的研究。

Tel: 18817879540

E-mail: 1633575852@qq.com



通讯作者: 尹慧琳 (1977–), 女, 山东人。博士, 教席教授, 主要从事智能车环境认知, 自动驾驶预期功能安全等方面的研究。

E-mail: liangsuqiuyue1122@163.com