

激光即时定位与建图算法综述

刘志成, 王华龙, 马兴录

(青岛科技大学 信息科学技术学院, 山东 青岛 266061)

摘要: 激光即时定位与建图 (SLAM) 算法是一种在机器人导航和自动驾驶领域被广泛应用的技术; 该技术可以利用激光雷达扫描环境并提取特征点, 实现机器人的自主定位和地图构建; 针对机器人激光 SLAM 技术进行研究, 分析了各个激光 SLAM 算法的基本原理, 并且对主流 SLAM 算法进行了现状总结; 根据激光 SLAM 算法的特点以及原理不同, 将激光 SLAM 算法分为: 基于滤波器的算法、基于图优化的算法、基于配准的算法、基于学习的算法等; 基于上述分类, 详细介绍了每个算法的优缺点, 并且分述了近两年的主要研究成果; 针对移动机器人激光 SLAM 算法研究现状, 对激光 SLAM 算法的未来发展进行了展望。

关键词: 即时定位与建图; 特征提取; 匹配; 优化; 未来发展

Summary of Laser Real-time Positioning and Mapping Algorithm

LIU Zhicheng, WANG Hualong, MA Xinglu

(Institute of Information Technology, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Laser simultaneous localization and mapping (SLAM) algorithm is widely used in the fields of robot navigation and autonomous driving; The technique can use lidar to scan the environment and extract feature points, realize the autonomous positioning and map construction of the robot; The robotic laser SLAM technology is researched to analyze the underlying principles of the various laser SLAM algorithms, and summarize the mainstream SLAM algorithm; According to the characteristics and principles of the laser SLAM algorithm, The laser SLAM algorithm is divided into the filter-based algorithm, graph optimization-based algorithm, registration-based algorithm, learning-based algorithm and other algorithms; Based on the above classification, It introduces the advantages and disadvantages of each algorithm in detail, and describes the main research results of the past two years; For the research status of laser SLAM algorithm in mobile robot, the future development of the laser SLAM algorithm is discussed.

Keywords: real-time positioning and construction drawing; feature extraction; matching; optimization; future development

0 引言

激光即时定位与建图 (SLAM, simultaneous localization and mapping) 是机器人领域中的关键技术, 它可以利用激光雷达扫描环境并提取特征点, 实现机器人的自主定位和地图构建。近年来, 随着机器人技术和激光雷达技术的不断发展, 激光 SLAM 也得到了广泛的研究和应用。

目前, 国内外对于激光 SLAM 的研究主要集中在以下几个方面: 算法优化, 硬件平台, 应用场景等^[1]。在算法优化方面, 研究人员不断探索和改进各种激光 SLAM 算法, 如基于优化的 SLAM 算法、基于点云配准的 SLAM 算法、基于学习的 SLAM 算法等, 以提高算法的精度和鲁棒性, 并降低计算复杂度和硬件要求。在硬件平台方面, 研究人员致力于开发更加高效、精准和稳定的激光雷达, 以及与之配套的机器人平台。在应用场景方面, 研究人员不断探索和拓展激光 SLAM 在各种实际应用场景的应用, 如室内

导航、无人驾驶、智能物流等。

1 国外激光 SLAM 算法研究现状与应用

随着人工智能的发展, 目前国外在激光 SLAM 方面的主要研究现状有算法优化、多传感器融合以及深度学习与 SLAM 等。激光 SLAM 主要应用在自动驾驶、机器人、AR/VR 以及无人飞行器等方面。也有大量国外学者针对相关激光 SLAM 算法的缺点和不足进行了大量研究并且发表了很多优秀文章, 例如, 对于基于滤波器的 SLAM 算法, 具有局限性, 如计算复杂度高、粒子数目选择、粒子退化等问题, 在文献 [2-3] 中通过对粒子滤波算法改进, 有效地解决了粒子退化, 提高了精度。文献 [4-5] 中提出深度学习的滤波器算法, 对非线性噪声进行建模, 提高了算法的精度和鲁棒性。对于基于图优化的 SLAM 算法, 存在一些缺点有计算复杂性、实时性、局部最优解等, 在文献 [6-9] 中主要举例 UKF-SLAM 算法, 通过改进算法, 有效

收稿日期: 2023-04-17; 修回日期: 2023-05-17。

作者简介: 刘志成(1998-), 男, 硕士。

通讯作者: 马兴录(1970-), 男, 硕士, 副教授。

引用格式: 刘志成, 王华龙, 马兴录. 激光即时定位与建图算法综述[J]. 计算机测量与控制, 2024, 32(3): 1-8.

地解决了计算复杂度高、粒子退化问题，并且对处理大规模环境时具有较好的效果。文献 [10-11] 举例了 Gmapping 算法，通过对激光雷达数据中的特征点进行提取和匹配，减少了计算量和存储空间，提高了算法的效率和存储空间。对于基于配准的 SLAM 算法，缺点有对环境要求较高，在未知环境或者动态环境可能存在一定的局限性等，文献 [12-17] 主要针对算法对环境不稳定和噪声干扰等问题，提出了一系列方法，有效地降低噪声和误差的影响，使得地图更加精确和鲁棒。对于基于学习的 SLAM 算法，具有数据依赖性、过拟合以及解释性差等缺点，文献 [18-21] 主要采用了分类聚类算法对点云数据进行处理，减少点云数据的噪声和不完整性，通过选取最有的聚类中心，提高了聚合器的效率和准确性。文献 [22-26] 中研究学者分别提出了不同的深度强化学习的 SLAM 算法，有效地提高了算法的性能和效率，解决了过拟合等问题。

2 激光 SLAM 算法综述

总的来说，激光 SLAM 的算法可以分为传统的基于滤波器和基于图优化的算法，以及近年来兴起的基于点云配准和基于学习的算法。如图 1 所示分类图。

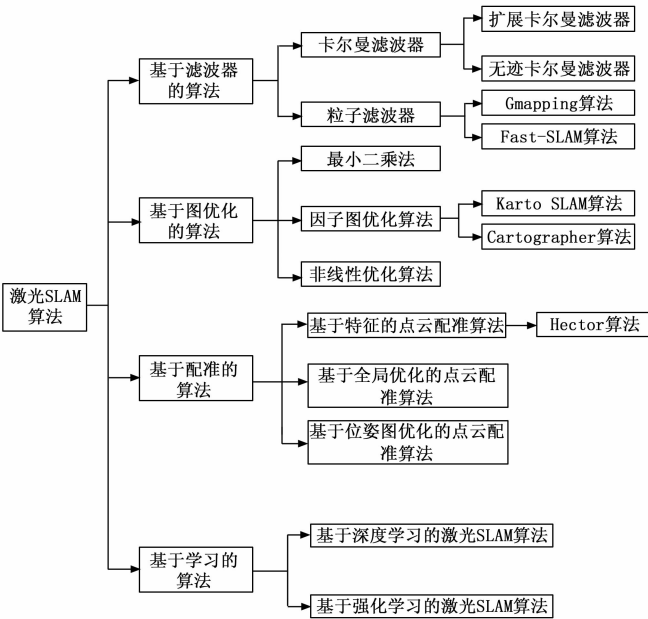


图 1 激光 SLAM 算法分类图

2.1 基于滤波器的算法

基于滤波器的 SLAM 算法主要利用不同类型的滤波器对机器人的轨迹和地图进行估计和优化。基于滤波器的算法一般有卡尔曼滤波器 SLAM 算法和粒子滤波器 SLAM 算法。

2.1.1 卡尔曼滤波器

卡尔曼滤波器是一种经典的线性高斯模型的状态估计滤波器，由美国工程师 R. E. Kalman 于 1960 年提出^[27]。该滤波器主要用于对系统状态的估计和预测，其基本原理

是通过系统状态和观测数据进行加权平均，获得更准确的状态估计结果。在 SLAM 中的应用主要是对机器人的位姿和地图进行估计和优化。基于卡尔曼滤波器的 SLAM 算法包括 EKF-SLAM 和 UKF-SLAM 等，它们的基本原理都遵循卡尔曼滤波器的原理机制，即状态的估计和预测，从而获得更准确的位姿和地图估计结果^[28]。下面分别介绍。

基于扩展卡尔曼滤波器的 SLAM 算法 (EKF-SLAM) 有两个阶段：预测和更新。其算法如表 1 所示。

表 1 扩展卡尔曼滤波器算法步骤

Prediction	Update
1) From state space model: $\mathbf{X}_t = \mathbf{F}_{t-1} \mathbf{X}_{t-1} + \mathbf{B}_{t-1} \mathbf{U}_{t-1}$ 2) Covariance Matrix: $\mathbf{P}_t = \mathbf{F}_{t-1} \mathbf{P}_{t-1} \mathbf{F}_{t-1}^T + \mathbf{Q}_{t-1}$ 在 $t=0$ 时刻我们可以初始化 \mathbf{P} 为： $\begin{bmatrix} 0.1 & 0 & 0 \\ 0 & 0.2 & 0 \\ 0 & 0 & 0.1 \end{bmatrix}$	3) Kalman Gain: $\mathbf{K}_t = \mathbf{P}_t \mathbf{H}_t^T (\mathbf{H}_t \mathbf{P}_t \mathbf{H}_t^T + \mathbf{R}_t)^{-1}$ 4) Update state: $\mathbf{X}_t = \mathbf{X}_t + \mathbf{K}_t (z_t - \mathbf{H}_t \mathbf{X}_t)$ 其中 z_t 和 \mathbf{X}_t 分别为来自传感器的实际测量和使用时间 t 的观察模型进行预测测量。 5. Update covariance matrix: $\mathbf{P}_t = (\mathbf{I} - \mathbf{K}_t \mathbf{H}_t) \mathbf{P}_t$
$\mathbf{Q}_{t-1} = \begin{bmatrix} \mathbf{C}(x,x) & \mathbf{C}(x,y) & \mathbf{C}(x,\gamma) \\ \mathbf{C}(y,x) & \mathbf{C}(y,y) & \mathbf{C}(y,\gamma) \\ \mathbf{C}(\gamma,x) & \mathbf{C}(\gamma,y) & \mathbf{C}(\gamma,\gamma) \end{bmatrix}$	

表 1 显示了扩展卡尔曼滤波器的预测和更新步骤。在预测步骤中，我们首先使用状态空间来估计状态 X_t 。然后，我们使用之前在时间 $t-1$ 处的协方差矩阵 \mathbf{P} 获得时间 t 处的状态协方差矩阵 \mathbf{P} 。在初始时刻我们没有协方差矩阵，需要自己初始化它。EKF-SLAM 算法的主要优点是能够处理非线性和非高斯问题，具有较高的估计精度和实时性。缺点是非线性噪声问题：EKF-SLAM 算法假设传感器噪声为线性高斯噪声，但实际上很多传感器噪声是非线性的，这会导致 EKF-SLAM 算法的精度下降；粒子退化问题：EKF-SLAM 算法使用的是单个最优的估计值，因此在处理大规模环境时，容易出现粒子退化问题，影响算法的效率和精度。

基于无迹卡尔曼滤波器的 SLAM 算法 (UKF-SLAM) 主要思想是通过无迹变换将非线性函数变换成一个高斯分布，从而实现对非线性问题的处理。具体来说，UKF-SLAM 算法将机器人的轨迹和地图表示为一个联合高斯分布，通过无迹变换对非线性函数进行线性化，从而实现对机器人轨迹和地图的估计和优化。具体来说，UKF-SLAM 算法包括以下步骤。

1) 状态预测：

① 通过机器人的运动模型和控制输入，计算机器人的预测状态。

② 通过无迹变换，将预测状态映射到高斯分布上。

③ 计算高斯分布的均值和协方差矩阵，作为机器人的预测状态

2) 状态更新：

① 通过机器人的观测数据，计算机器人当前的观测

状态。

② 通过无迹变换, 将观测状态映射到高斯分布上。

③ 计算机器人位姿和地图的联合高斯分布的均值和协方差矩阵, 作为机器人的最终状态。

3) 地图优化:

① 使用非线性优化方法对地图进行优化, 以进一步提高估计精度。

② 通过无迹变换, 将优化后的地图状态映射到高斯分布上。

③ 计算机器人位姿和地图的联合高斯分布的均值和协方差矩阵, 作为机器人的最终状态和地图状态。

UKF-SLAM 算法是一种使用无迹卡尔曼滤波器(UKF)进行 SLAM 的方法, 相比于 EKF-SLAM, UKF-SLAM 具有更好的非线性建模能力和更少的线性化误差。然而, UKF-SLAM 仍然存在一些缺点, 如计算复杂度高、粒子退化等^[6]。

2.1.2 粒子滤波器

粒子滤波 SLAM (PF-SLAM) 是一种基于蒙特卡罗方法的非参数滤波器, 最初由 Dieter Fox 等人提出, 发表于 2003 年的 ICRA 会议上, 用于同时估计机器人的轨迹和环境地图^[29]。其主要思想是使用一组状态粒子来估计机器人的位姿和环境地图, 在 PF-SLAM 中, 每个状态粒子表示机器人的一个假设位姿和地图, 它们的权重表示该假设与真实状态的匹配程度。在预测和重采样过程中, 每个粒子的权重被用来决定其在新粒子集中的数量, 从而使更有可能的粒子数量增加, 不太可能的粒子数量减少。这样, 通过多次迭代, 可以逐渐减小估计误差, 实现对机器人轨迹和环境地图的估计。如图 2 是粒子滤波算法流程图。常见的基于粒子滤波的 SLAM 算法有 FastSLAM 算法、Gmapping 算法等。

其中 FastSLAM 算法使用了分解式滤波的思想, 将地图分解为一系列特征, 每个特征由一个粒子来描述, 同时对于每个特征, 都估计了其对应的位姿, 从而实现机器人轨迹和地图的同时估计, 大大降低了计算复杂度。

FastSLAM 算法的基本流程如下:

1) 初始化粒子集合和地图: 随机生成一组粒子, 每个粒子都表示机器人的位姿和地图的状态;

2) 预测粒子状态: 根据运动模型对每个粒子进行预测, 得到机器人的位姿;

3) 更新粒子权重: 根据观测数据, 计算每个粒子的权重, 表示该粒子对应的状态与观测数据的匹配程度;

4) 重采样: 根据粒子的权重对粒子进行重采样, 使得权重大的粒子被选中的概率更高;

5) 更新地图: 对每个粒子的地图进行更新, 包括添加新的特征和更新已有特征的状态。

FastSLAM 算法的优点是具有良好的鲁棒性和实时性, 适用于多种不同的机器人和环境。由于采用了分解式滤波

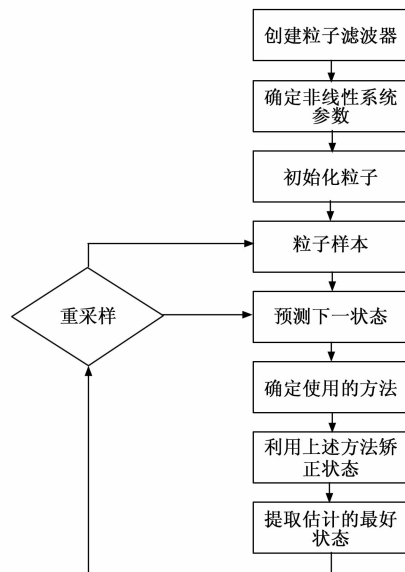


图 2 粒子滤波算法流程图

的思想, 将地图分解为一系列特征, 极大地降低了计算复杂度, 同时还可以处理非线性运动模型和非线性观测模型。FastSLAM 算法的缺点是对于大规模地图的处理效果不如基于图优化的 SLAM 算法, 同时在处理复杂环境时容易出现粒子退化的问题, 即大部分粒子的权重趋于零, 导致估计精度下降。

Gmapping 算法原理是使用栅格地图来表示环境, 并利用粒子滤波器来进行位姿估计和地图构建。具体来说, Gmapping 算法通过将环境划分为一系列小的栅格单元, 每个栅格单元一共有 3 种状态: 占有、空闲、未知。如图 3 所示为栅格示意图, 在栅格中黑色表示占有, 白色表示空闲, 灰色表示未知。该算法通过激光雷达对周围环境进行扫描, 对检测范围内的网格根据占有概率将其判定为占有或空闲, 通过机器人的移动对未知网格进行探索, 并使用激光雷达数据进行障碍物检测和栅格地图更新直到地图建立完成。同时, 算法使用粒子滤波器对机器人的位姿进行估计, 并根据估计的位姿和激光雷达数据来更新栅格地图。最终, 通过多次迭代, Gmapping 算法可以得到高精度的栅格地图和机器人的位姿估计。

Gmapping 算法的优点包括可以处理复杂的环境, 如室内环境、城市街道等。可以构建高精度的栅格地图, 对机器人的定位能力提供了较好的支持。对激光雷达数据的噪声和误差具有较强的鲁棒性。Gmapping 算法的缺点包括需要进行大量的计算, 特别是在处理大规模环境时, 计算复杂度会急剧增加。依赖于激光雷达, 对于没有激光雷达的机器人来说不适用。

2.2 基于图优化的算法

基于图优化的算法是一种常用于 SLAM 问题的方法, 最早出现在 20 世纪 80 年代, 主要用于解决机器人路径规划和 SLAM 等问题^[30-31]。其主要思想是将机器人在环境中的




图 3 网格示意图

运动轨迹和环境的拓扑结构建模成一个图，然后通过优化图中的节点和边来最小化误差，得到机器人的位姿估计和环境的地图。图优化 SLAM 算法主要包括前端和后端两个过程，其算法框架如图 4 所示。前端负责数据关联和闭环检测，数据关联主要来处理局部数据关系，解决连续数据帧间的匹配以及相关姿态估计的问题。闭环检测主要针对全局数据关系，通过传感器所获得数据判断机器人当前位姿与之前已访问区域位姿之间的匹配及相对位姿估计问题。通过上述两个过程完成位姿图的创建，即图优化 SLAM 的前端。由于传感器与观测噪声和扫描匹配自身误差的缘故会导致前端获得的位姿图有偏差，因此需要后端图优化部分对位姿图进行修正^[32]。后端处理不直接对传感器的观测数据进行处理，而是仅对前端创建的位姿图进行优化，得到位姿的最大似然估计即最优的位姿序列。常见的基于图优化的 SLAM 算法有最小二乘法 SLAM，因子图优化算法，非线性优化算法等。

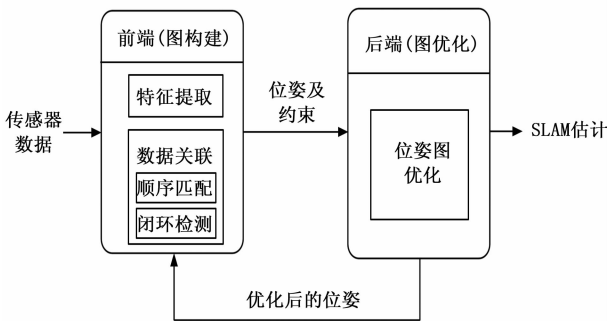


图 4 基于图优化方法的 SLAM 算法框架

在基于图优化 SLAM 算法中，机器人的位姿序列以及位姿间的约束关系可以转化成如图 5 所示。

在图 5 中 $x = (x_i, x_j, \dots)^T$ 表示机器人的位姿序列，它是一个向量，在图中表示点集，其中 x_i 和 x_j 分别代表 i 节点和 j 节点的位姿； z_{ij} 表示 i 节点和 j 节点的相对位姿，即不同时刻下的关联信息； Ω_{ij} 代表节点 i 和节点 j 之间的信息矩阵； $f_{ij}(x)$ 为测量函数，表示在理想情况下的测量值； $e_{ij}(x)$ 代表向量误差函数，即测量值与预测值的差。

假设误差函数 $e_{ij}(x)$ 服从高斯分布，则目标函数可表示




图 5 机器人位姿转化为图的表示方法

为如下形式：

$$F_{ij}(x) \propto (f_{ij}(x) - z_{ij})^T \Omega_{ij} (f_{ij}(x) - z_{ij}) \quad (2)$$

$$F_{ij}(x) \propto e_{ij}(x)^T \Omega_{ij} e_{ij}(x) \quad (3)$$

由上面的表达式可知，只需找到节点 x^* 使得目标函数 $F_{ij}(x)$ 的值最小即可获得最优解，即

$$x^* = \operatorname{argmin} F(x) \quad (4)$$

2.3 基于配准的算法

基于配准的 SLAM 算法基本思想是通过匹配两帧或多帧激光雷达或相机捕捉到的点云数据，估计每个时刻机器人的位姿并构建地图^[33]。该算法通常分为两个步骤：前端配准和后端优化。前端配准是指对连续的点云数据进行匹配，以得到机器人的运动轨迹和局部地图。后端优化则是指对前端得到的轨迹和地图进行全局优化，以进一步提高位姿估计和地图质量。常见的基于配准的激光 SLAM 方法分为基于特征的点云配准算法、基于全局优化的点云配准算法和基于位姿图优化的点云配准算法。其中主流的 SLAM 算法就是 Hector 算法。

Hector-SLAM 主要原理是通过激光雷达数据获取环境地图，并同时估计机器人在地图中的位置和姿态，实现自主导航和环境建图。Hector 整体算法很直接，就是将激光点与已有的地图“对齐”，即扫描匹配。扫描匹配就是使用当前帧与已经有的地图数据构建误差函数，使用高斯牛顿法得到最优解和偏差量。其工作是实现激光点到栅格地图的转换， t 时刻所有的激光点都能变换到栅格地图中，也就意味着匹配成功。如表 2 所示，Hector-SLAM 主要包括以下几个步骤：

通过以上步骤，Hector-SLAM 能够在实时性和精度之间取得良好的平衡。Hector 算法具有以下优点：实时性较高，Hector SLAM 算法利用线段作为路标，提高了匹配效率，同时使用 EKF 进行位姿估计，保证了实时性；精度较高，Hector SLAM 算法在路标提取、位姿估计、闭环检测和地图优化等方面都有较好的设计，能够提高地图的精度和鲁棒性。缺点有：对环境要求较高；鲁棒性有待提高，算法对于激光雷达数据的噪声和不确定性较为敏感，需要进一步提高算法的鲁棒性。

表 2 Hector 算法步骤

激光雷达数据预处理	将激光雷达数据进行去噪、滤波、分割等预处理,得到一系列激光点云。
构建占据栅格地图	将激光点云转换为占据栅格地图,其中栅格的值表示该位置是否被占据。
路标提取	从地图中提取路标,并利用路标进行位姿估计。Hector SLAM 使用线段作为路标,因为线段具有较好的鲁棒性和描述能力。
位姿估计	通过匹配当前激光雷达数据和上一帧激光雷达数据对应的路标点,利用扩展卡尔曼滤波(EKF)对机器人的位置和姿态进行估计。
地图更新	根据机器人当前位置和激光雷达数据更新地图,同时将新的路标加入路标库。
闭环检测	使用 Scan Context 进行闭环检测,即在地图中寻找与当前帧相似的历史帧,并使用这些历史帧对当前位置进行校正。
地图优化	在闭环检测后,使用非线性优化算法对地图进行优化,以进一步提高地图的准确性和鲁棒性。

2.4 基于学习的算法

基于学习的 SLAM 算法是指利用机器学习的方法,通过对传感器数据和地图数据的学习,实现环境建图和自主导航的技术。这种方法可以从数据中自动提取特征,避免了手动设计特征的困难和不确定性,同时具有较好的泛化能力和鲁棒性^[34]。基于学习的 SLAM 算法主要解决了传统 SLAM 算法中存在的以下问题:特征设计问题,传统 SLAM 算法需要手动设计特征,这存在一定的主观性和不确定性,这增加了算法的难度和复杂度。基于学习的 SLAM 算法可以从数据中自动学习特征,避免了手动设计特征的困难和不确定性;实时性问题,传统 SLAM 算法需要大量的计算和存储资源,对实时性的要求较高,基于学习的 SLAM 算法可以通过端到端的学习和高效的计算方法,提高算法的实时性和效率;建图准确性问题,传统 SLAM 算法在环境建图中容易出现漏洞和误差,基于学习的 SLAM 算法可以通过数据的学习和模型的优化,提高建图的准确性和精度^[18]。目前,基于学习的 SLAM 算法主要包括以下几种:深度学习 SLAM 以及强化学习 SLAM。

2.4.1 基于深度学习的 SLAM 算法

基于深度学习的激光 SLAM 算法主要利用深度学习技术来解决 SLAM 算法中的以下几个问题:特征提取,传统的 SLAM 算法需要手动设计特征点,但这些特征点的选择和设计往往具有一定的主观性和不确定性^[35]。而基于深度学习的 SLAM 算法可以通过卷积神经网络等对激光数据进行特征提取,自动提取出图像和激光数据中的特征点、线段、平面等特征^[36];点云配准,传统的 SLAM 算法中需要通过点云配准来实现环境建图和定位,但这通常需要进行复杂的数学计算。基于深度学习的 SLAM 算法可以通过学

习大量数据,利用深度学习模型学习点云之间的相似性和差异性,从而实现点云的配准和匹配;地图优化,基于深度学习的激光 SLAM 算法可以通过学习大量数据,利用深度学习模型学习地图的结构和特征,从而实现地图的自适应优化,提高地图的准确性和鲁棒性^[37]。目前主流的几个基于深度学习的激光 SLAM 算法有 PointNetVLAD 算法、PointNetGPD 算法、DeepMapping 算法以及 LIO-SAM 算法等。

2.4.2 基于强化学习的激光 SLAM 算法

基于强化学习的 SLAM 算法主要思想是将 SLAM 问题转化为一个强化学习问题,并使用强化学习方法进行求解。最早是在 2016 年提出的,由芬兰赫尔辛基大学的研究者首次将强化学习应用于 SLAM 问题中^[38]。

该算法将 SLAM 问题看作一个强化学习问题,其中机器人作为一个智能体,通过与环境的交互来学习最优的行为策略,从而实现同时定位和地图构建。具体来说,算法使用一个价值函数来评估机器人当前状态和行动的价值,并通过一系列的行动来最大化累计回报,最终实现优化的定位和地图构建结果。如表 3 所示基于强化学习的激光 SLAM 算法步骤如表 3。

表 3 基于强化学习的激光 SLAM 算法步骤

步骤	方法
环境建模	在 SLAM 问题中,机器人需要对环境进行建模,包括建立地图和定位机器人。基于强化学习的 SLAM 算法将这个问题看作一个强化学习问题,机器人需要在未知环境中学习最优的行为策略,同时实现定位和地图构建。
状态表示	基于强化学习的 SLAM 算法将机器人的状态表示为一个向量,包括机器人的位置、速度、方向等信息,同时也包括地图的信息。
行动选择	机器人根据当前状态选择一个行动,行动的选择是根据价值函数来实现的,价值函数用于评估机器人当前状态和行动的价值,并选择最优的行动。
环境交互	机器人执行所选择的行动,与环境进行交互,并获取环境的反馈信息,包括传感器数据、位置信息等。
状态更新	机器人根据环境反馈信息更新自己的状态,包括位置、速度、方向等信息。
奖励计算	在 SLAM 问题中,机器人的奖励通常定义为位置估计误差和地图构建误差的函数,奖励函数的设计对算法的性能和效果具有重要影响。
强化学习更新	机器人根据奖励计算更新自己的策略和价值函数,以最大化累计回报。
迭代更新	机器人不断地与环境交互、更新状态、选择行动、计算奖励、更新价值函数,直到收敛为止。

3 激光 SLAM 算法分析与应用

本文对目前主流的激光 SLAM 算法进行了简单的归纳

和综述,并且对每一种 SLAM 算法列举了其实现机制和原理,以及优缺点和改进等。这四类激光 SLAM 算法的联系在于它们都是利用激光雷达数据来实现机器人的自我定位和地图构建,但是具体实现方式和特点有所不同。四类算法相对于其他算法的改进主要表现在以下方面。

基于滤波器的激光 SLAM 算法:这类算法使用卡尔曼滤波器、扩展卡尔曼滤波器等滤波器来实现激光 SLAM,具有计算速度快、适用于小规模场景等优点。但是,由于滤波器的线性化假设,这类算法对于非线性问题的处理效果不如基于优化的算法。常见的应用场景包括室内环境、小型机器人等。

基于图优化的激光 SLAM 算法:这类算法使用非线性优化方法,如图优化、束优化等,来精确估计机器人的位姿和地图,能够处理非线性问题和大规模场景。但是,这类算法计算复杂度较高,处理速度较慢。常见的应用场景包括无人车、大型机器人等。

基于配准的激光 SLAM 算法:这类算法使用点云配准方法来实现激光 SLAM,能够处理复杂地形和多层次地图。但是,由于配准算法对初始位姿较为敏感,因此需要先验信息或者较为准确的初始位姿。常见的应用场景包括室外环境、地下矿井等。

基于学习的激光 SLAM 算法:这类算法使用深度学习技术来实现激光 SLAM,能够自动学习特征表示,具有较强的泛化能力。但是,由于深度学习技术的数据需求量较大,这类算法需要大量的训练数据。常见的应用场景包括室内环境、室外环境等。

不同的激光 SLAM 算法适用于不同的应用场景,需要根据具体场景来综合考虑选择哪种算法。

4 激光 SLAM 算法发展趋势

本文综述了移动机器人激光 SLAM 算法的原理、优缺点、研究现状和改进。激光 SLAM 算法是机器人实现自主导航和环境感知的关键技术。随着激光雷达技术和机器学习等技术的不断发展,激光 SLAM 算法也在不断更新和发展。以下是激光 SLAM 算法未来的发展趋势和展望:

多传感器融合:随着各种传感器技术的不断发展和普及,多传感器融合已经成为激光 SLAM 算法发展的趋势之一,并且已经取得了不错的成绩,例如文献 [39-40],传感器融合可以提高定位精度和鲁棒性。

深度学习技术应用:未来深度学习技术将被更广泛地应用于激光 SLAM 算法中,例如文献 [35-37]、文献 [41],将深度学习用于点云配准、建图和定位等方面。此外,基于学习的激光 SLAM 算法已经取得了不俗的成绩,未来也将会会有更多的基于学习的算法被提出。

实时性和效率:随着机器人应用场景的不断扩大,对激光 SLAM 算法的实时性和效率的要求也越来越高。因此,未来的激光 SLAM 算法将更加注重算法的实时性和效率,

并且会结合分布式计算、GPU 加速等技术来提高算法的实时性和效率。

大规模场景处理:传统的激光 SLAM 算法在大规模场景中往往面临着精度不高、计算量大等问题,因此未来的激光 SLAM 算法将更加注重大规模场景的处理,如分布式 SLAM、增量式 SLAM 等算法。此外,一些基于图优化的方法、基于机器学习的方法也在被不断地提出和改进。

自主决策和交互:未来的激光 SLAM 算法不仅仅是用于机器人自我定位和地图构建,更会结合机器人的自主决策和交互能力,例如文献 [42]。如基于 SLAM 的路径规划、环境感知等。未来的激光 SLAM 算法将更加注重机器人与环境的交互和合作,如机器人对环境的理解和预测等。

总之,未来激光 SLAM 算法将更加注重新多传感器融合、深度学习技术应用、实时性和效率、大规模场景处理以及自主决策和交互等方面,这些发展趋势将推动激光 SLAM 算法的不断更新和发展^[43-75]。

5 结束语

激光 SLAM 算法是移动机器人的关键技术,目前的激光 SLAM 算法具有一定的局限性,仍需要大量工作进行改进,提高算法的性能和实用性等。总之,激光 SLAM 算法的未来发展充满了机遇和挑战,期待着激光 SLAM 算法在未来的发展中不断地创新和突破,为机器人应用带来更加优秀和可靠的解决方案。

参考文献:

- [1] CAMPBELL A M, BURNETT K, WALTER M R. Deep reinforcement learning for SLAM: experiments with LiDAR and vision [J]. *Autonomous Robots*, 2021, 45 (8): 1929 - 1947. <https://doi.org/10.1007/s10514-021-09941-6>.
- [2] 王吉, 朱国荣, 张明. 基于相机的 EKF-SLAM 算法 [J]. *电子学报*, 2013, 41 (3): 484 - 489.
- [3] 王志鹏, 王峰, 王艳玲. 基于改进粒子滤波的 EKF-SLAM 算法 [J]. *中国惯性技术学报*, 2012, 20 (6): 654 - 659.
- [4] SMITH R C, CHEESEMAN P. On the representation and estimation of spatial uncertainty [J]. *The International Journal of Robotics Research*, 1986, 5 (4): 56 - 68.
- [5] MONTEMERLO M, THRUN S, KOLLER D, et al. FastSLAM: A factored solution to the simultaneous localization and mapping problem [C] // In AAI/IAAI, 2003: 593 - 598.
- [6] 张鑫, 李伟, 李欣, 等. 非线性卡尔曼滤波研究进展综述 [J]. *自动化学报*, 2015, 41 (5): 667 - 682.
- [7] 韩巍, 王杰, 陈琳琳, 等. 基于并行粒子滤波的 UKF-SLAM 算法 [J]. *机器人*, 2017, 39 (2): 264 - 271.
- [8] 王曜, 赵建中, 张瑶, 等. 基于改进粒子滤波的 UKF-SLAM 算法 [J]. *机器人*, 2016, 38 (3): 314 - 320.
- [9] 赵炜, 刘志强, 李海峰, 等. 基于稀疏特征的 UKF-SLAM 算法 [J]. *机器人*, 2014, 36 (4): 422 - 429.

- [10] 胡 杨, 郭 强, 王 兵, 等. 基于改进粒子滤波的 Gmapping 算法 [J]. 仪器仪表学报, 2018, 39 (7): 216 - 223.
- [11] 刘文强, 王兴华, 郑成峰, 等. 基于特征点的 Gmapping 算法 [J]. 机器人, 2011, 33 (1): 1 - 7.
- [12] ZHANG F, PANG L, SHAO M, et al. Improved Hector SLAM Algorithm for Mobile Robot Mapping Based on Lidar [J]. Sensors, 2021, 41 (5): 141 - 147.
- [13] GAO L, ZHANG R, CHEN G, et al. An Improved Hector SLAM Algorithm Based on Deep Learning [J]. IEEE Access, 2021, 9: 20354 - 20363.
- [14] MENG F, HUANG S, WANG W, et al. An Improved Hector SLAM Algorithm Based on Parallel Computing [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1 - 10.
- [15] LI Y, WU Q, WANG J, et al. A Deep Learning-based Hector SLAM Algorithm for Mobile Robot Mapping [C] // 2020 39th Chinese Control Conference (CCC). IEEE, 2020: 4371 - 4376.
- [16] ZHANG X, LIU Y, LIU H, et al. A Hector SLAM with Multiple Sensor Fusion for Mobile Robot Mapping [C] // 2020 2nd IEEE International Conference on Robotics and Automation Sciences (ICRAS). IEEE, 2020: 148 - 152.
- [17] ZHANG H, LIU J, LIU X, et al. Parallel Computing Based Hector SLAM Algorithm for Mobile Robot Mapping [C] // 2020 3rd International Conference on Robotics, Control and Automation Engineering (RCAE). Atlantis Press, 2020: 417 - 422.
- [18] CHEN Y, WANG D, LU F, et al. Learning-based Visual SLAM: A Comprehensive Review [J]. Sensors, 2021, 21 (11): 3670.
- [19] 刘文强, 王兴华, 郑成峰, 等. 基于特征点的 Gmapping 算法 [J]. 机器人, 2011, 33 (1): 1 - 7.
- [20] LU F, MILIOS E, NISTER D. Sparse extended information filtering: A scalable algorithm for SLAM [J]. IEEE Transactions on Robotics, 2016, 32 (3): 545 - 561.
- [21] DALLAERT F, KAESS M. Square root SAM: Simultaneous localization and mapping via square root information smoothing [J]. The International Journal of Robotics Research, 2006, 25 (12): 1181 - 1202.
- [22] GUPTA S, DAVIDSON J, LEVINE S, et al. Cognitive mapping and planning for visual navigation [J]. International Journal of Computer Vision, 2017, 126 (9): 973 - 997.
- [23] MIROWSKI P, PASCANU R, VIOLA F, et al. Learning to navigate in complex environments [J]. IEEE transactions on pattern analysis and machine intelligence, 2018, 41 (3): 611 - 624.
- [24] CADENA C, CARLONE L, CARRILLO H, et al. Past, present, and future of simultaneous localization and mapping: Toward the robust-perception age [J]. IEEE Transactions on robotics, 2016, 32 (6): 1309 - 1332.
- [25] ALEXANDER KRONER, ANDREAS ZELL. Learning to Map in Unknown Environments with Deep RL [J]. IEEE Robotics and Automation Letters, 2021, 6 (2): 348 - 355.
- [26] ZHOU T, HOU X, ZHANG K, et al. Deep Reinforcement Learning for Autonomous Navigation and Mapping: A Survey [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21 (8): 3314 - 3331.
- [27] KALMAN R E. A new approach to linear filtering and prediction problems [J]. Transactions of the ASME-Journal of Basic Engineering, 1960, 82 (Series D): 35 - 45.
- [28] 张 鑫, 王 岩, 王宇航. 基于 EKF 的 SLAM 算法研究 [J]. 机器人, 2015, 37 (6): 711 - 718.
- [29] FOX D, BURGARD W, THRUN S. Monte Carlo localization: Efficient position estimation for mobile robots [C] // Proceedings of the Sixteenth National Conference on Artificial Intelligence. AAAI Press/The MIT Press, 1999: 343 - 349.
- [30] LU F, MILIOS E, NISTER D. Sparse extended information filtering: A scalable algorithm for SLAM [J]. IEEE Transactions on Robotics, 2016, 32 (3): 545 - 561.
- [31] DALLAERT F, KAESS M. Square root SAM: Simultaneous localization and mapping via square root information smoothing [J]. The International Journal of Robotics Research, 2006, 25 (12): 1181 - 1202.
- [32] KONOLIGE K, BOWMAN J, CHEN J, et al. Towards life-long visual maps from episodic memory [J]. The International Journal of Robotics Research, 2010, 29 (13): 1574 - 1595.
- [33] 刘 鑫, 王宝义, 赵 宇, 等. 基于配准的 SLAM 算法综述 [J]. 机器人, 2018, 40 (3): 375 - 387.
- [34] 张 鑫, 刘 彦, 陈宏伟. 基于深度学习的视觉 SLAM 算法研究综述 [J]. 自动化学报, 2021, 47 (2): 241 - 259.
- [35] 刘 鑫, 王宝义, 张 峰, 等. 基于深度学习的激光 SLAM 算法研究进展 [J]. 激光与光电子学进展, 2020, 57 (20): 2016001.
- [36] 郑宇峰, 周 兴, 孙振兴. 激光 SLAM 中基于深度学习的特征提取方法研究 [J]. 中国科技论文, 2020, 15 (32): 4072 - 4080.
- [37] 吴 伟, 沈 凯, 王宝义, 等. 基于深度学习的多传感器融合 SLAM 算法研究进展 [J]. 控制与决策, 2020, 35 (7): 1527 - 1538.
- [38] TUNG L C, HUANG H Y, WANG W C. A Survey of Reinforcement Learning in Simultaneous Localization and Mapping [J]. IEEE Transactions on Cognitive and Developmental Systems, 2020, 12 (3): 576 - 593.
- [39] 肖昌庆, 郑 宇, 王永强, 等. 多传感器融合在 SLAM 中的应用研究 [J]. 自动化学报, 2021, 47 (4): 684 - 702.
- [40] 郭梦玲, 赵云飞, 李旭东, 等. 基于多传感器融合和深度神经网络的非线性优化 SLAM 算法改进方案 [J]. 仪器仪表学报, 2021, 42 (6): 753 - 767.
- [41] ARANDJELOVIC R, ZISSERMAN A. All About VLAD [C] // In Proceedings of the IEEE Conference on Computer

- Vision and Pattern Recognition, 2013; 1578–1585.
- [42] 赵凯华, 王晓峰, 李亚丽, 等. 分布式优化算法研究综述 [J]. 控制与决策, 2017, 32 (10): 1741–1752.
- [43] 吴 华, 王 峰, 刘俊杰, 等. 基于多传感器融合的最小二乘法 SLAM 算法 [J]. 计算机工程与科学, 2017, 39 (1): 133–142.
- [44] 王新宇, 黎孟辉, 王 杰, 等. 基于数据关联的最小二乘法 SLAM 算法 [J]. 自动化学报, 2014, 40 (4): 607–616.
- [45] 陈 伟, 张晓雷, 刘卫国. 基于增量式最小二乘法的 SLAM 算法 [J]. 计算机科学, 2010, 37 (2): 216–218, 251.
- [46] BESL P J, MCKAY N D. A method for registration of 3-D shapes [J]. IEEE Transactions on pattern analysis and machine intelligence, 1992, 14 (2): 239–256.
- [47] 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.
- [48] HUANG A, BACHRACH A, HENRY P, et al. Visual odometry and mapping for autonomous flight using an RGB-D camera [C] // In Robotics and Automation (ICRA), 2013: 2104–2111.
- [49] GRISETTI G, KÜMMERLE R, STACHNISS C, et al. A tutorial on graph-based SLAM [J]. IEEE Intelligent Transportation Systems Magazine, 2010, 2 (4): 31–43.
- [50] ZHANG H, LI X, LI B, et al. Laser and Visual SLAM Fusion for Robust Localization [J]. IEEE Robotics and Automation Letters, 2020, 5 (2): 2248–2255.
- [51] WANG Z, LIU X, ZHANG J, et al. An Incremental Optimization SLAM Algorithm for Mobile Robots [J]. Journal of Intelligent & Robotic Systems, 2020, 99 (2): 443–454.
- [52] HESS W, KOHLER D, RAPP H, et al. Real-time loop closure in 2D LIDAR SLAM [C] // In Proceedings of the ROSCon, 2016; 3 (2).
- [53] ZHANG Q, LI K, LI K, et al. DeepCartographer: A Deep-Learning-Based Autonomous Mapping System [J]. IEEE Robotics and Automation Letters, 2021, 6 (2): 2998–3005.
- [54] CHEN X, ZHANG Y, LIU, Y, et al. MSCartographer: Multi-Sensor Data Fusion for Robust and Efficient SLAM [J]. IEEE Access, 2021, 9: 13967–13980.
- [55] HU Y, CHEN X, ZHANG Y, et al. LoopCartographer: Efficient Loop Closure Detection for Real-Time SLAM [J]. IEEE Robotics and Automation Letters, 2021, 6 (4): 6802–6809.
- [56] 王 桢, 李 健, 李 嘉, 等. DynCartographer: 2D 激光雷达动态物体感知建图 [J]. 机器人, 2021, 43 (3): 345–354.
- [57] 王宏志, 韩志超, 谭建国, 等. 非线性优化在计算机视觉中的应用 [J]. 自动化学报, 2016, 42 (9): 1277–1292.
- [58] CHEN X, WANG C, SHI Q, et al. Learning-assisted visual SLAM: a survey [J]. Journal of Field Robotics, 2018, 35 (8): 1244–1264.
- [59] WANG F, QIU Q, ZHU S, et al. DeepVIO: A deep learning approach for monocular visual-inertial odometry [J]. Robotics and Automation Letters, IEEE, 2019, 4 (4): 3717–3724.
- [60] ZHANG W, LIU Y, LI X, et al. GC-SLAM: Graph Convolutional SLAM for Large-Scale Multi-Session and Multi-Mission Stereo Visual Odometry [J]. Robotics and Automation Letters, IEEE, 2020, 5 (2): 1123–1130.
- [61] GONG H, ZHAO Y, LI X, et al. Conf-SLAM: A Robust and Efficient Robotic SLAM Algorithm Using Confidence Information [J]. IEEE Transactions on Instrumentation and Measurement, 2019, 68 (12): 4655–4666.
- [62] WEI M, HU H, HUANG J, et al. MT-SLAM: Multi-Target Slam Based on Joint Multi-Object Tracking and Nonlinear Optimization [J]. IEEE Transactions on Robotics, 2018, 34 (1): 229–244.
- [63] DENG F, LIU K, ZHAO Y, et al. SE-SLAM: A Semantic Segmentation Enhanced SLAM System with Nonlinear Optimization [J]. IEEE Transactions on Robotics, 2022, 38 (1): 195–206.
- [64] JIANG J, LI F, WANG H, et al. MT-Conf-SLAM: A Non-linear Optimization SLAM Algorithm Based on Multi-Object Tracking and Confidence Factor Graph [J]. IEEE Transactions on Instrumentation and Measurement, 70, 1–12.
- [65] 郭俊杰, 王 嘉, 张 欣, 等. 基于扩展信息滤波的改进 Hector SLAM 算法 [J]. 智能与机器人系统学报, 2021, 101: 1–10.
- [66] ZU F, ZHANG H, LI C. PointNetVLAD: Deep Point Cloud Based Retrieval for Large-Scale Place Recognition [J]. IEEE Robotics and Automation Letters, 2019, 4 (3): 3713–3720.
- [67] ZHANG M, LIU S, HUANG X. Large-Scale Direct Monocular SLAM [C] // In Proceedings of the IEEE International Conference on Robotics and Automation (ICRA), 2018: 1–8.
- [68] KONOLIGE K, BOWMAN J, CHEN J, et al. Towards life-long visual maps from episodic memory [J]. The International Journal of Robotics Research, 2010, 29 (13): 1574–1595.
- [69] WANG S, ZHANG Y, LI J, et al. Multi-Robot SLAM Based on LIO-SAM with Consistency Constraints [J]. IEEE Access, 2021, 9: 100934–100943.
- [70] ZHANG Y, WANG S, LI J, et al. Robust Point Cloud Registration for LiDAR-Based SLAM Using LIO-SAM [J]. IEEE Robotics and Automation Letters, 2021, 7 (2): 421–428.
- [71] YANG Y, ZHANG X, HSU L, et al. LIO-SAM-Loop: Loop Closure Detection for LiDAR-Based SLAM Systems [J]. IEEE Robotics and Automation Letters, 2022, 7 (4): 5620–5627.
- [72] 王 雪, 王晓伟, 王志伟. 基于改进的重采样方法的 FastSLAM 算法 [J]. 计算机应用, 2013, 33 (4): 947–951.
- [73] 陈 荣, 张 玲, 钟 元, 等. 基于稀疏卷积神经网络的 FastSLAM 算法 [J]. 控制工程, 2018, 25 (1): 55–61.
- [74] 雷 媛, 王晓伟, 王志伟. 基于分层采样的 FastSLAM 算法 [J]. 计算机工程与科学, 2012, 34 (10): 138–142.
- [75] 胡兴华, 姚 昆, 王志伟, 等. 基于分块共轭梯度下降的最小二乘法 SLAM 算法 [J]. 机器人, 2016, 38 (2): 225–231.