arXiv:2305.01843v1 [cs.RO] 3 May 2023

直接激光雷达-惯性里程计与建图：感知与连接式同步定位与建图

Kenny Chen[1], Ryan Nemiroff[1],和 Brett T. Lopez[2]

摘要——**本文介绍了直接激光雷达-惯性里程计与建图（DLIOM），这是一种稳健的 SLAM 算法，明确侧重于计算效率、运行可靠性和真实世界有效性。DLIOM 在前端和后端子系统中融入了多项关键算法创新，旨在设计一种能够感知环境的韧性激光雷达-惯性架构，为自主机器人平台实现精准定位和高保真三维建图。我们的构想源于对现代激光雷达同步定位与地图构建系统的深入研究，以及对其难以适应不同运行环境这一问题的考察。针对若干常见算法故障点，我们采用主动防护措施，以确保系统在非结构化真实环境中的长期运行可靠性。我们详细介绍了贯穿典型激光雷达同步定位与地图构建流水线的多项重要创新，这些创新提升了定位精度和建图韧性，并全面提高了算法的速度、精度与稳健性。此外，我们还分享了从头构建这一复杂系统、使其能够在资源受限系统上进行实时状态估计过程中获得的经验，并通过实验表明，与当前最先进的方法相比，我们的方法在公开基准数据集和自行采集的数据集上均有更出色的表现。**

索引词—**定位、建图、里程计、状态估计、同步定位与建图、激光雷达、惯性测量单元、传感器融合、野外机器人技术**

一、引言

精准的实时状态估计与建图是自主机器人感知、规划和在未知环境中导航的基石能力。此类能力要实现长期运行可靠性，必须具备算法韧性，以应对颗粒物（如灰尘或雾）、低照度、恶劣或非结构化地形等非标称条件及其他外部因素。视觉同步定位与建图方法在光照良好的环境中或许有效，但由于对环境的假设过强、架构脆弱或计算复杂度过高，它们在真实环境中很快就会失效。另一方面，得益于更轻便、价格更低廉的传感器，基于激光雷达的方法近来已成为许多移动平台的可行选择。因此，研究人员近期开发了若干新的激光雷达里程计（LO）和激光雷达-惯性里程计（LIO）系统；由于激光雷达传感器在距离与深度测量方面表现更优，这些系统往往优于基于视觉的定位。

[1]Kenny Chen 和 Ryan Nemiroff 任职于美国加利福尼亚州洛杉矶的加利福尼亚大学洛杉矶分校电气与计算机工程系。 {kennyjchen, ryguyn}@ucla.edu[2]Brett T. Lopez 任职于美国加利福尼亚州洛杉矶的加利福尼亚大学洛杉矶分校机械与航空航天工程系。 btlopez@ucla.edu 所有作者均就职于美国加利福尼亚州洛杉矶的加利福尼亚大学洛杉矶分校可验证与控制理论机器人实验室。

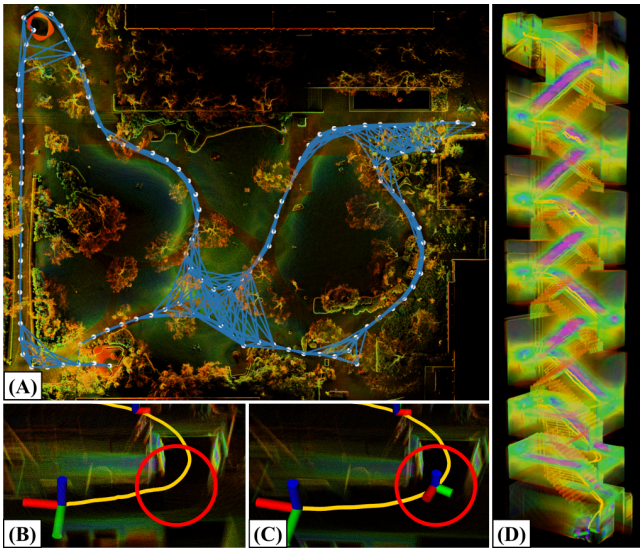


图 1. **稠密连接映射与弹性定位。** 我们提出的 DLIOM 算法针对激光雷达里程计中的常见故障点设置了多项主动防护措施，从而构建了一个能够适应运行环境的弹性同步定位与建图框架。(A) UCLA雕塑花园的俯视图，由 DLIOM 建图生成，展示了算法构建的位姿图，其中关键帧间约束实现了局部精度和全局弹性。(B 和 C) DLIOM 抗滑移关键帧选取的示例，该方法有助于锚定扫描到地图配准；突发的场景变化（例如穿过一扇门）通常会导致滑移（B），而场景变化检测（C）可以缓解这一问题。(D) DLIOM 生成的八层楼梯地图，展示了我们的算法能够跟踪定位的复杂环境。

测量精度。然而，在开发稳健、可长期运行且以激光雷达为核心的同步定位与建图解决方案时，仍面临若干根本性挑战，尤其是对于探索未知环境、执行敏捷机动或穿越不平坦地形的自主机器人 [1]。

通过针对同步定位与建图中的常见故障点建立主动防护机制来增强算法韧性，可在广泛的运行环境中实现感知能力强且具备容错能力的定位，从而确保长期可靠性。现有算法在结构化环境中可能表现良好，因为这类环境能够为后端优化器提供约束充分的问题；但在非规则条件下，其性能可能迅速下降，导致感知系统速度缓慢且脆弱，无法满足现实应用的需求。近期少数能够实时适应不同条件的方法中，有些依赖在退化环境中切换到其他传感模态 [2]，，有些则需要根据人工指定的启发式规则执行复杂的参数调优流程 [3]，[4]，，还有些仅专注于扫描匹配过程，以便更好地约束弱约束配准问题 [5]。

为此，本文提出了直接激光雷达惯性

里程计与建图（DLIOM）算法。这是一种鲁棒的实时SLAM系统，包含多项关键创新，可提高定位与建图的韧性和精度（图 1）。本工作的主要贡献有五项，分别针对典型的LiDAR SLAM架构中的特定模块（以粗体标出），全面提升算法的速度、精度和鲁棒性：

- **关键帧选择**：一种抗滑移关键帧选取方法，通过全局且与传感器无关的退化度量，在场景骤变时检测扫描匹配滑移的开始。
- **子地图构建**：一种生成明确相关的局部子地图并实现最大覆盖范围的方法，通过计算每个关键帧的相对三维杰卡德指数来进行扫描到地图配准。
- **建图**：一种通过连通性因子和基于关键帧的回环闭合，提高局部建图精度和全局回环闭合鲁棒性的方法。
- **扫描匹配**：一种自适应扫描匹配方法，通过新颖的点云稀疏度指标，在大规模和小规模环境中实现一致配准。
- **运动校正**：一种新颖的由粗到精技术，可实现快速且可并行化的逐点运动校正；该方法基于恒定加加速度和角加速度运动模型推导出一组解析方程，用于构建连续时间轨迹。

本文在算法和实验方面大幅扩展了我们此前的工作《直接激光雷达惯性里程计》（DLIO） [6]。具体而言，除连续时间运动校正之外，上述各项贡献都是原创性的关键思想，旨在提高算法精度、泛化能力和故障鲁棒性。此外，我们从零开始构建的方法带来了新的算法见解；我们还提供了新的实验结果，展示了与当前最先进方法相比，本方法在算法鲁棒性、计算效率以及整体地图和轨迹精度方面的表现。

II. 相关工作

用于三维飞行时间传感器（例如激光雷达）的同时定位与建图（SLAM）算法，通过求解非线性最小二乘问题来对齐点云，使对应点和/或平面之间的误差最小化。为寻找点/平面对应关系，迭代最近点（ICP）算法 [7], [8], 广义迭代最近点 (GICP) [9], 或正态分布变换 [10]等常用方法会递归匹配潜在的对应实体，直到对齐收敛至局部最小值。在为大量点确定对应关系时，通常会出现收敛速度缓慢的情况，因此，基于特征的方法 [11]–[18]尝试仅提取扫描数据中最显著的数据点（例如角点和边缘），以减少计算时间。然而，特征提取的效果高度依赖于具体实现。此外，有用的点往往会被丢弃，导致估计值和地图不准确。相反，稠密方法 [2], [19]–[22]直接对齐获取的扫描数据，但通常严重依赖激进的体素化——这一过程可能会改变重要的数据对应关系——以实现实时性能。

激光雷达里程计方法还可以根据其将其他传感模态纳入估计流程的方式进行广泛分类。松耦合方法 [2], [11], [12], [19], [20] 按顺序处理数据。例如，IMU测量值通过提供优化先验，用于增强激光雷达扫描配准。由于激光雷达测量的精确性，这些方法通常具有很强的鲁棒性，但由于估计时仅使用了所有可用数据的一个子集，定位结果可能不够准确。紧耦合方法 [13], [17], [18], [21], [23], 另一方面，可以通过联合考虑来自所有传感模态的测量值来提高精度。这些方法通常采用基于图的优化 [13], [17],[18], [24]或随机滤波框架，例如卡尔曼滤波器 [16], [21]。然而，与几何观测器 [25], [26],相比，即使在最理想的设置下，这些方法也几乎不具备收敛保证，可能因不一致的传感器融合而产生显著的定位误差，并因不正确的扫描放置而导致地图变形。

融合其他传感器也有助于正确校正运动引起的点云畸变。例如，LOAM [11]通过迭代估计传感器位姿进行扫描匹配，并结合采用恒定速度假设的松耦合惯性测量单元，补偿旋转畸变。同样，LIO-SAM [13] 基于因子图构建激光雷达-惯性里程计，以联合优化机体速度；在其实现中，随后通过对旋转运动进行线性插值来校正点的运动畸变。FAST-LIO [16] 和 FAST-LIO2 [21]则在对惯性测量单元测量值进行前向传播后，针对点时间戳执行反向传播步骤，从而获得相对于扫描结束时刻的相对变换。然而，这些方法（以及其他方法 [27], [28]）均采用离散时间处理，这可能导致精度损失，因此连续时间方法备受关注。例如，Elastic LiDAR Fusion [29], 通过优化连续线性轨迹来处理扫描形变；而 Wildcat [30] 和 [31] 则通过迭代拟合三次B样条，消除面元地图中的畸变。近期，CT-ICP [32] 和 ElasticLiDAR++ [33]采用仅激光雷达方案，以每次扫描对应两个位姿的方式对连续时间轨迹进行参数化，从而能够在优化过程中对扫描进行弹性配准。然而，在高度动态运动下，这些方法对轨迹的建模仍可能过于简单，也可能计算开销过大，无法可靠地实时运行。

LIO系统中的另一个关键组件是子地图构建，它通过从全局地图中提取较小的点云来提高处理效率并增强位姿估计一致性。由于在每次迭代中处理整个地图通常会导致计算量大到难以实现，子地图只包含待处理的全部可用数据点中的一个子集。然而，子地图构建策略的有效性取决于它能否仅提取与扫描匹配最相关的地图点，从而避免在构建相应的数据结构（即 k-d 树、法向量）时浪费计算资源。一种常见方法是使用滑动窗口，使子地图由一组近期扫描数据组成 [18],[34]。然而，该方法假设时间相关性很强，♀♀♀

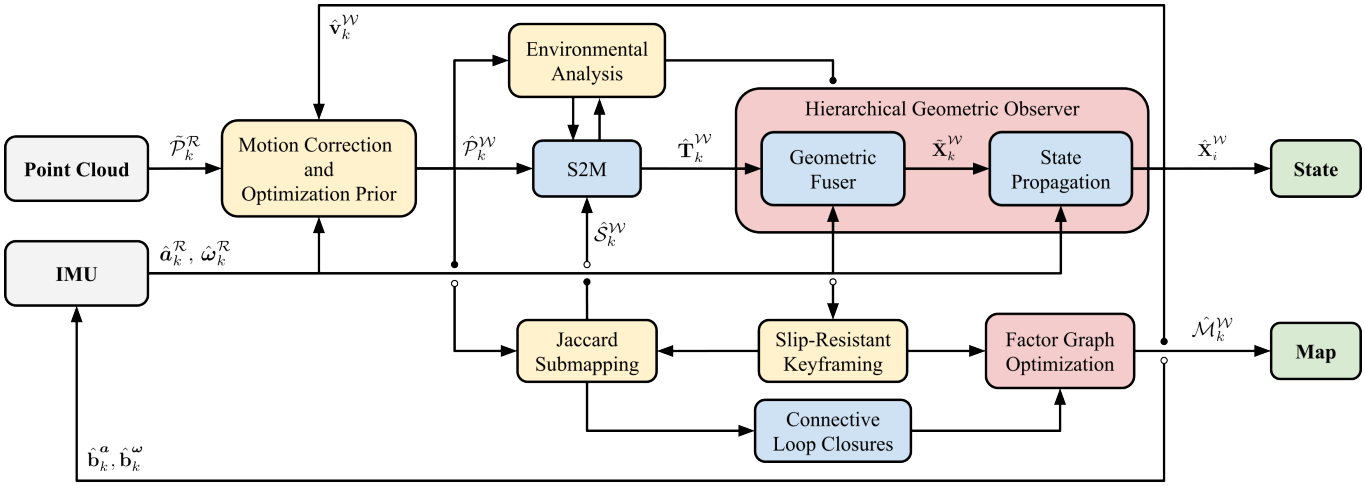


图 2. **系统架构**。 DLIOM 的双管齐下架构包含多项关键创新，旨在提供具备现实环境运行可靠性的完整 SLAM 流水线。在 $\mathcal{W}$ 中进行的逐点连续时间积分确保校正后点云具有最高保真度，并由定制的基于GICP的扫描匹配器将其配准到机器人的地图中。对环境结构和扫描匹配状态的分析可提供多项系统指标，用于自适应调整最大对应距离，并进行抗滑移关键帧选取。此外，还会针对每个关键帧与当前扫描计算三维杰卡德指数，以最大限度地提高子地图覆盖率，从而增加扫描匹配对应关系。随后，系统状态由具有强收敛特性的非线性几何观测器更新；这些位姿、速度和偏置估计值继而用于初始化下一次迭代。之后，系统状态还会发送至后台建图线程，该线程在关键帧位置放置位姿图节点，并通过关键帧间约束构建连通图，以确保局部精度和全局韧性。

</style id='1'>点之间的对应关系并非总是成立（例如，重访某个位置时），且在发生显著漂移时可能表现不佳。为缓解这一问题，基于半径的方法[13], [19]直接处理点云，提取当前位置附近的点，并持续将其添加到内部八叉树数据结构中。然而，这会导致地图 [35] 不断膨胀，并因所需的大量最近邻计算而使计算开销激增，无法满足实时使用需求。另一方面，基于关键帧的方法 [13], [20], 将空间中的关键位置与相应的扫描关联起来，从而缩小提取完整子地图所需的搜索空间。然而，先前的方法 [6], [20]仍然隐含地假设附近的关键帧包含子地图最相关的数据点，并未针对每个关键帧显式计算相关性指标，因此可能提取出根本不会被使用的关键帧。

近年来，研究人员一直致力于将新的算法韧性方法融入里程计流水线，以确保在各种环境中实现可靠的定位。尽管自适应定位领域仍处于起步阶段，但早期研究已在非结构化和/或极端环境中率先探索了自适应性的理念。例如，为了增强在几何退化环境下应对激光雷达滑移的韧性，LION [2],、DARE-SLAM [36]，和 DAMS-LIO [37] 提议使用扫描匹配海森矩阵的条件数作为可观测性评分，从而切换至不同的状态估计算法（例如，视觉惯性算法）。然而，这些研究假设机载具备其他里程计范式，而这类条件并不总是能够满足。另一方面，诸如 [3] 和 [4] 的研究尝试基于轨迹误差建模自动调整系统超参数，但这需要昂贵的离线训练流程来获取最优参数值且无法泛化到训练集之外的其他环境。类似地，KISS-ICP [35] 会自适应地调整迭代最近点的最大对应距离，但其方法根据机器人加速度对度量尺度进行缩放，因此无法泛化到规模各异的环境。另一方面，AdaLIO [38]，会在检测到退化情形时，自动调整体素化、搜索距离和平面残差参数。全局闭环检测方法也可以通过地点识别和重定位来帮助减少地图中的漂移，例如使用 ScanContext [39], [40] 和 Segregator [41]等描述子和检测器。最近，[24]和 X-ICP [5]分别提出了创新的在线方法，通过分析扫描到扫描和扫描到地图中优化约束的几何结构来缓解退化，但这些工作仅针对整个复杂 SLAM 流水线中的某个特定模块。

为此，DLIOM 提出了多种适用于基于激光雷达的 SLAM 系统的新技术，以解决前端和后端存在的若干缺陷。我们的方案针对数据处理流水线中的不同尺度，逐步提高定位韧性和建图精度。首先，采用一种快速的由粗到精的方法，在每次激光雷达扫描之间构建连续时间轨迹，以实现精确且可并行化的逐点运动校正。随后，通过自适应扫描匹配技术，将这些经过运动校正的点云逐步与提取的子地图进行配准。该技术根据当前点云的稀疏度调整最大对应距离，从而确保在不同环境中实现一致的配准。每个提取的子地图均通过计算各环境关键帧相对于当前扫描匹配问题的相关性来显式生成，计算依据为相对三维杰卡德指数；这样做是为了最大限度地提高子地图覆盖率，从而增强扫描与子地图之间的数据关联。为防止滑移，扫描匹配健康度会持续.....

通过一种新颖的与传感器无关的退化度量进行实时监测：当快速场景变化期间优化约束过弱时，插入新的关键帧。最后，为提高局部建图精度和全局回环闭合韧性，我们计算关键帧间重叠度，为基于关键帧的因子图建图器提供额外因子。

III. 系统概述与数据处理

DLIOM是一种稳健的同步定位与建图算法，特别注重定位韧性、建图精度以及真实环境中的运行可靠性（图2）。该架构包含两个并行线程，分别实时处理里程计估计和全局建图。首先，激光雷达扫描数据会依次进行运动校正，然后与基于关键帧的子地图配准，以为集成后的IMU测量值提供精确的更新信号。通过为一致的扫描匹配自适应设置最大对应距离，并显式推导局部子地图，确保这一精度；推导过程中，通过为每个环境关键帧计算三维杰卡德指数，保证当前扫描获得最大的子地图覆盖率。这有助于提高GICP优化过程中对数据关联误差的鲁棒性。一种用于计算环境退化的新方法提供了扫描匹配滑移的全局视角，并持续监测优化健康状态，在滑移开始前立即插入新的关键帧；此外，非线性几何观测器融合激光雷达扫描匹配与IMU预积分，以实现高频状态估计，并提供可认证收敛保证。

在第二条线程中，关键帧不断扩展内部因子图：每个关键帧都表示为图中的一个节点，而关键帧对之间的各种约束则表示为节点间的因子。相邻关键帧之间的“顺序”因子为位姿图提供了坚实的骨干，这得益于我们系统精准的局部里程计；重叠关键帧之间的“连接”因子（通过其三维杰卡德指数确定）则提高了局部地图精度，并增强了全局地图抵御灾难性错误回环闭合的韧性。此类回环闭合后的帧偏移会得到谨慎处理，以避免估计速度出现不连续，从而实现安全的机器人控制。我们的算法从底层开始完全自主构建，旨在降低计算开销、提高算法容错性和现实环境中的可靠性。

A. 数学符号

将时间 t_k 开始的单次激光雷达扫描的点云记为 $\mathcal{P}_k$，并以 k为索引。点云$\mathcal{P}_k$ 由点 $p_k^n \in \mathbb{R}^3$ 组成，这些点是在相对于扫描开始时刻 Δt_k^n 测得的，并以$n = 1, \ldots, N$为索引，其中 N是扫描中的点总数。世界坐标系记为 $\mathcal{W}$，机器人坐标系记为 $\mathcal{R}$，其原点位于重心；按照约定，x朝前、y 朝左、z 朝上。惯性测量单元的坐标系记为 $\mathcal{B}$，激光雷达的坐标系记为 $\mathcal{L}$，机器人状态向量$\mathbf{X}_k$ 在索引 k 处定义为以下元组

$$\mathbf{X}_k = \left[\, \mathbf{p}_k^{\mathcal{W}},\, \mathbf{q}_k^{\mathcal{W}},\, \mathbf{v}_k^{\mathcal{W}},\, \mathbf{b}_k^{\boldsymbol{a}},\, \mathbf{b}_k^{\boldsymbol{\omega}} \,\right]^{\top}, \tag{1}$$

算法 1： DLIOM：里程计线程

输入： $\hat{}\mathbf{X}_{k\text{-}1}^{\mathcal{W}}, \hat{}\mathcal{M}_k^{\mathcal{W}}, \mathcal{P}_k^{\mathcal{L}}, \boldsymbol{a}_k^{\mathcal{B}}, \boldsymbol{\omega}_k^{\mathcal{B}}$; **输出：** $\hat{}\mathbf{X}_i^{\mathcal{W}}$

// 激光雷达回调线程
当 $\mathcal{P}_k^{\mathcal{L}} \neq \emptyset$ **时做**
  // 初始化点并将变换应用于 $\mathcal{R}$
  $\tilde{\mathcal{P}}_k^{\mathcal{R}} \leftarrow$ initializePointCloud($\mathcal{P}_k^{\mathcal{L}}$); (III-B)
  // 构造粗略轨迹
  对于 $\hat{}\boldsymbol{a}_i^{\mathcal{R}}, \hat{}\boldsymbol{\omega}_i^{\mathcal{R}}$在 $t_{k\text{-}1}$ 和 t_k 之间**执行**
    $\hat{}\mathbf{p}_i, \hat{}\mathbf{v}_i, \hat{}\mathbf{q}_i \leftarrow$ 离散积分($\hat{}\mathbf{X}_{k\text{-}1}^{\mathcal{W}}, \hat{}\boldsymbol{a}_{i\text{-}1}^{\mathcal{R}}, \hat{}\boldsymbol{\omega}_{i\text{-}1}^{\mathcal{R}}$); (5)
    $\hat{\mathbf{T}}_i^{\mathcal{W}} = [\, \hat{\mathbf{R}}(\hat{}\mathbf{q}_i) \,|\, \hat{}\mathbf{p}_i \,]$;
  end
  // 连续时间运动校正
  对于 $p_k^n \in \tilde{\mathcal{P}}_k^{\mathcal{R}}$ **执行**
    $\hat{\mathbf{T}}_n^{\mathcal{W}*} \leftarrow$ continuousInt($\hat{\mathbf{T}}_i^{\mathcal{W}*}, t_n$) ; (6)
    $\hat{}p_k^n = \hat{}\mathbf{T}_n^{\mathcal{W}*} \otimes p_k^n$; $\hat{}\mathcal{P}_k^{\mathcal{W}}$.append($\hat{}p_k^n$);
  end
  // 环境分析：
  // 计算宽敞度和点云稀疏度
  $m_k, z_k \leftarrow$ 计算自适应参数(<escape>$\hat{}\mathcal{P}_k^{\mathcal{W}}$); [20], (11)</escape>
  // 通过三维杰卡德指数构建子地图
  对于 $\mathcal{K}_j^{\mathcal{W}} \in \hat{}\mathcal{M}_k^{\mathcal{W}}$, **执行**
    $J(\hat{\mathcal{P}}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}}) \leftarrow |\hat{\mathcal{P}}_k^{\mathcal{W}} \cap \mathcal{K}_j^{\mathcal{W}}| \,/\, |\hat{\mathcal{P}}_k^{\mathcal{W}} \cup \mathcal{K}_j^{\mathcal{W}}|$; (9)
    如果 $J(\hat{\mathcal{P}}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}}) \geq thresh_{jaccard}$ **然后**
      $\hat{}\mathcal{S}_k^{\mathcal{W}}$.append($\hat{}\mathcal{P}_k^{\mathcal{W}}$);
    end
  end
  // 自适应扫描到地图配准
  $\hat{\mathbf{T}}_k^{\mathcal{W}} \leftarrow$ 广义迭代最近点($\hat{\mathcal{P}}_k^{\mathcal{W}}, \hat{\mathcal{S}}_k^{\mathcal{W}}, z_k$) ; (10)
  // 抗滑移关键帧选取
  if $\hat{\mathcal{P}}_k^{\mathcal{W}}$是一个关键帧，通过（7）或 [20]**然后**
    $\mathcal{K}_k^{\mathcal{W}} \leftarrow \hat{}\mathcal{P}_k^{\mathcal{W}}$;
    // 计算新的关键帧重叠度，并
    // 添加到连通性矩阵
    对于 $\mathcal{K}_j^{\mathcal{W}} \in \hat{}\mathcal{M}_k^{\mathcal{W}}$ **执行**
      $\mathbf{C}_{kj} \leftarrow J(\mathcal{K}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}})$; (V-A)
    end
    // 发送新的关键帧和更新后的
    // 连通性矩阵至建图线程
    odom2map($\mathcal{K}_k^{\mathcal{W}}$, $\mathbf{C}$);
  end
  // 几何观测器：状态更新
  $\hat{\mathbf{X}}_k^{\mathcal{W}} \leftarrow$ 更新状态($\hat{}\mathbf{T}_k^{\mathcal{W}}$, Δt_k^+); (IV-D)
  返回 $\hat{\mathbf{X}}_k^{\mathcal{W}}$
结束
// IMU 回调线程
当 $\boldsymbol{a}_i^{\mathcal{B}} \neq \emptyset$ 且 $\boldsymbol{\omega}_i^{\mathcal{B}} \neq \emptyset$ **时执行**
  // 对 $\mathcal{R}$ 应用偏置并进行变换
  $\hat{\boldsymbol{a}}_i^{\mathcal{R}}, \hat{\boldsymbol{\omega}}_i^{\mathcal{R}}$ <escape>← </escape>initializeImu(<escape> $\boldsymbol{a}_i^{\mathcal{B}}$</escape>,<escape> $\boldsymbol{\omega}_i^{\mathcal{B}}$ </escape>); (III-B)
  // 几何观测器：状态传播
  $\hat{\mathbf{X}}_i^{\mathcal{W}} \leftarrow$ propagateState($\hat{\mathbf{X}}_k^{\mathcal{W}}, \hat{\boldsymbol{a}}_i^{\mathcal{R}}, \hat{\boldsymbol{\omega}}_i^{\mathcal{R}}, \Delta t_i^+$); (IV-D)
  返回 $\hat{\mathbf{X}}_i^{\mathcal{W}}$
结束

其中 $\mathbf{p}^{\mathcal{W}} \in \mathbb{R}^3$ 是机器人的位置，$\mathbf{q}^{\mathcal{W}}$ 是通过 $\mathbb{S}^3$ 上的四元数表示的姿态，遵循 Hamilton 约定。

算法 2： DLIOM：建图线程

输入： $\mathcal{K}_k^{\mathcal{W}}$，$\mathbf{C}$，$\mathcal{G}_k$；**输出：** $\hat{\mathcal{M}}_k^{\mathcal{W}}$

初始化： $\mathcal{G}_k$.addPriorFactor($\mathcal{K}_0^{\mathcal{W}}$)

// 关键帧回调线程

当 $\mathcal{K}_k^{\mathcal{W}} \neq \emptyset$ 且 $\mathbf{C} \neq \emptyset$ **时**

  // 向前一个关键帧添加因子

  $\mathcal{G}_k$.addBetweenFactor($\mathcal{K}_{k-1}^{\mathcal{W}}, \mathcal{K}_k^{\mathcal{W}}$);

  // 向连接关键帧添加因子

  对于 $\mathcal{K}_j^{\mathcal{W}} \in \hat{\mathcal{M}}_k^{\mathcal{W}}$，**执行**

    如果 $\mathbf{C}_{kj} \geq thresh_{conn}$ **则**

      $\mathcal{G}_k$.addBetweenFactor($\mathcal{K}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}}$);

    end

  end

  // 基于子地图的闭环

  对于 $\mathcal{K}_j^{\mathcal{W}} \in \hat{\mathcal{M}}_k^{\mathcal{W}}$，**执行**

    如果 $\mathcal{K}_j^{\mathcal{W}}$是通过 *V-B*确定的回环候选，**则**

      $\mathcal{L}_k^{\mathcal{W}} \leftarrow \mathcal{L}_k^{\mathcal{W}} \oplus \mathcal{K}_j^{\mathcal{W}}$

    end

  end

  $\hat{\mathbf{T}} \leftarrow$ 广义迭代最近点($\mathcal{L}_k^{\mathcal{R}}, \hat{\mathcal{K}}_k^{\mathcal{R}}, z_k$); (10)

  如果适配度分数 $\geq thresh_{loop}$ **那么**

    $\mathcal{G}_k$.addBetweenFactor($\mathcal{K}_k^{\mathcal{W}}, \mathcal{K}_{\mathcal{L}}^{\mathcal{W}}$);

  end

  // 优化因子图

  $\mathcal{G}_k$.optimize($\mathcal{K}_k^{\mathcal{W}}$);

  // 优化后更新地图

    $\hat{\mathcal{M}}_k^{\mathcal{W}} \leftarrow$ 更新关键帧($\mathcal{G}_k$);

  // 发送至里程计线程

  map2odom($\hat{\mathcal{M}}_k^{\mathcal{W}}$);

  return $\hat{\mathcal{M}}_k^{\mathcal{W}}$

结束

记号中，$\mathbf{v}^{\mathcal{W}} \in \mathbb{R}^3$ 表示机器人速度，$\mathbf{b}^{\boldsymbol{a}} \in \mathbb{R}^3$ 表示加速度计偏置，而$\mathbf{b}^{\boldsymbol{\omega}} \in \mathbb{R}^3$ 表示陀螺仪偏置。来自惯性测量单元（IMU）的测量值 $\hat{\boldsymbol{a}}$ 和 $\hat{\boldsymbol{\omega}}$ 建模为

$$\hat{\boldsymbol{a}}_i = (\boldsymbol{a}_i - \boldsymbol{g}) + \mathbf{b}_i^{\boldsymbol{a}} + \mathbf{n}_i^{\boldsymbol{a}}, \tag{2}$$

$$\hat{\boldsymbol{\omega}}_i = \boldsymbol{\omega}_i + \mathbf{b}_i^{\boldsymbol{\omega}} + \mathbf{n}_i^{\boldsymbol{\omega}}, \tag{3}$$

并为 $i = 1$、……、M之间的 M次测量建立索引，测量时刻为 $t_{k\text{-}1}$ 和 t_k。稍微滥用一下符号，索引 k和 i 分别对应激光雷达和惯性测量单元的采样频率；为简洁起见，除非另有说明，均采用这种写法。原始传感器测量值 $\boldsymbol{a}_i$ 和 $\boldsymbol{\omega}_i$ 包含偏置$\mathbf{b}_i$ 和白噪声 $\mathbf{n}_i$，而 $\boldsymbol{g}$ 是旋转后的重力向量。在本文中，我们解决以下问题：给定来自激光雷达的畸变点云$\mathcal{P}_k$，以及来自惯性测量单元的 $\boldsymbol{a}_i$ 和 $\boldsymbol{\omega}_i$，估计机器人状态 $\hat{\mathbf{X}}_i^{\mathcal{W}}$ 和几何地图 $\hat{\mathcal{M}}_k^{\mathcal{W}}$。

B. 传感器数据预处理

DLIOM 的输入包括由现代 360° 机械式激光雷达（例如 Ouster 或 Velodyne，频率为 10–20Hz）采集的稠密三维点云，以及由六轴惯性测量单元以高得多的频率（100–500Hz）测得的时间同步的线加速度和角速度。为尽量减少信息损失，我们不对点云进行预处理，仅使用尺寸为 1m^3 、位于原点周围的盒式滤波器来移除

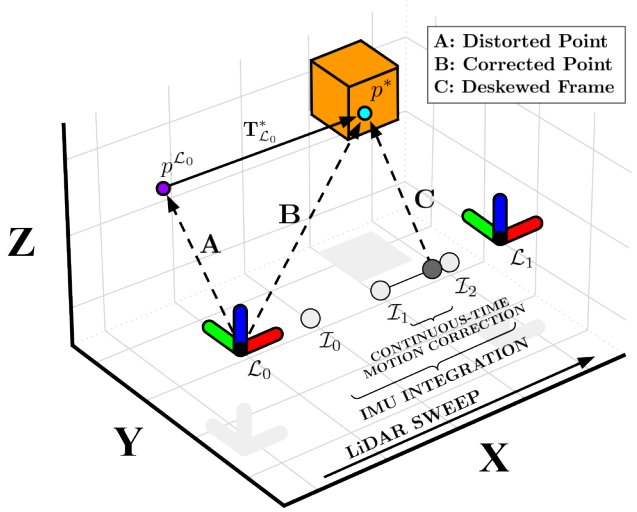


图 3. **由粗到细的点云去畸变**。畸变点 $p^{\mathcal{L}_0}$ (A) 通过两步过程进行去畸变：首先对扫描数据之间的惯性测量单元测量值进行积分，然后在连续时间 (C) 中求解该点的唯一变换，从而将 $p^{\mathcal{L}_0}$ 去畸变为 p^* (B)。

可能来自机器人自身的点，以及针对高分辨率点云的轻量体素滤波器。这使我们的工作区别于其他工作：后者要么尝试检测特征（例如角点、边缘和/或面元），要么对输入点云进行激进的降采样。平均而言，在我们的定制平台上，本研究使用的点云每次扫描包含 ~16,000 个点。

此外，在执行下游任务之前，所有传感器数据都会通过外参标定进行变换，使其位于 $\mathcal{R}$ 机器人重心处。对于激光雷达，每次采集的扫描都会通过

$$\mathcal{R}_{\mathcal{L}} \in \mathbb{SE}(3) \qquad [p^{\mathcal{R}}\ 1]^\top = \mathbf{T}(\cdot)\ {}^{\mathcal{R}}_{\mathcal{L}}[p^{\mathcal{L}}\ 1]^\top$$

进行旋转和平移，使得扫描中的每个点都满足$\mathbf{T}$。对于惯性测量单元，如果传感器未恰好位于重心处，则必须考虑刚体上线加速度测量值因位置偏移而产生的影响。为此，需要通过角速度与惯性测量单元和重心之间位移的叉积，考虑 $\mathcal{R}$ 处的所有线加速度贡献，从而对其进行补偿。对于在惯性测量单元坐标系中测得的原始线加速度$\boldsymbol{a}_i^{\mathcal{B}}$，假设位移恒定，则其在坐标系 $\mathcal{R}$ 中的对应线加速度为，

$$\hat{\boldsymbol{a}}_i^{\mathcal{R}} = \hat{\boldsymbol{a}}_i^{\mathcal{B}} + \left[\dot{\hat{\boldsymbol{\omega}}}_i^{\mathcal{R}} \times {}^{\mathcal{R}}_{\mathcal{B}}\mathbf{t}\right] + \left[\hat{\boldsymbol{\omega}}_i^{\mathcal{R}} \times \left(\hat{\boldsymbol{\omega}}_i^{\mathcal{R}} \times {}^{\mathcal{R}}_{\mathcal{B}}\mathbf{t}\right)\right] \tag{4}$$

其中，${}^{\mathcal{R}}_{\mathcal{B}}\mathbf{t}$ 是从 $\mathcal{B}$ 到 $\mathcal{R}$的平移距离，而 $\hat{\boldsymbol{\omega}}_i^{\mathcal{R}}$ 是$\hat{\boldsymbol{\omega}}_i^{\mathcal{B}}$，但仅旋转至符合坐标轴约定，因为刚体上各点的角速度相同。

C. Conti 连续时间运动校正与集成

先前旋转式激光雷达传感器生成的点云在运动过程中会产生运动畸变，这是因为旋转激光阵列在一次扫描期间的不同时间采集点。我们不再假设扫描期间物体进行简单运动（即恒定速度），因为这种假设可能无法准确捕捉细微运动；相反，我们采用更准确的恒定加加速度和角加速度模型，通过两步由粗到细传播方案为每个点计算唯一变换。这一策略旨在尽量减少因惯性测量单元采样率以及惯性测量单元与

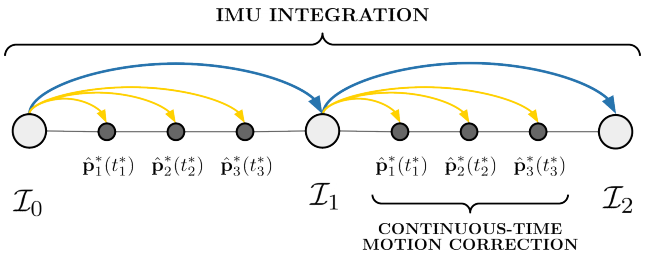


图 4. **连续时间运动校正**。 对于点云中的每个点，仅根据其时间戳对一组闭式运动方程求解，计算出唯一变换，从而实现精确的逐点连续时间运动校正。

激光雷达点测量。扫描期间的轨迹首先通过惯性测量单元数值积分进行粗略构建，随后通过求解一组解析连续时间方程进一步细化，方程见 $\mathcal{W}$ （图3）。

令 t_k 为接收到点云 $\mathcal{P}_k^{\mathcal{R}}$的时刻，点云中有$N$ 个点；令 $t_k + \Delta t_k^n$ 为点云中某个点 p_k^n 的时间戳。为了近似该点在 $\mathcal{W}$中的位置，我们首先对 $t_{k\text{-}1}$ 和$t_k + \Delta t_k^N$之间的IMU测量值进行积分，得到

$$\begin{aligned}
\hat{\mathbf{p}}_i &= \hat{\mathbf{p}}_{i\text{-}1} + \hat{\mathbf{v}}_{i\text{-}1}\Delta t_i + \tfrac{1}{2}\hat{\mathbf{R}}(\hat{\mathbf{q}}_{i\text{-}1})\hat{\boldsymbol{a}}_{i\text{-}1}\Delta t_i^2 + \tfrac{1}{6}\hat{\boldsymbol{j}}_i\Delta t_i^3\,,\\
\hat{\mathbf{v}}_i &= \hat{\mathbf{v}}_{i\text{-}1} + \hat{\mathbf{R}}(\hat{\mathbf{q}}_{i\text{-}1})\hat{\boldsymbol{a}}_{i\text{-}1}\Delta t_i\,,\\
\hat{\mathbf{q}}_i &= \hat{\mathbf{q}}_{i\text{-}1} + \tfrac{1}{2}(\hat{\mathbf{q}}_{i\text{-}1}\otimes\hat{\boldsymbol{\omega}}_{i\text{-}1})\Delta t_i + \tfrac{1}{4}(\hat{\mathbf{q}}_{i\text{-}1}\otimes\hat{\boldsymbol{\alpha}}_i)\Delta t_i^2\,,
\end{aligned} \tag{5}$$

对于 $i = 1$、.....、 M，其中 M表示两次扫描之间的IMU测量值数量；$\hat{\ } \boldsymbol{j}_i = \frac{1}{\Delta t_i}(\hat{\ }\mathbf{R}(\hat{\ }\mathbf{q}_i)\hat{\ }\boldsymbol{a}_i - \hat{\ }\mathbf{R}(\hat{\ }\mathbf{q}_{i\text{-}1})\hat{\ }\boldsymbol{a}_{i\text{-}1})$ 和 $\hat{\ }\boldsymbol{\alpha}_i = \frac{1}{\Delta t_i}(\hat{\ }\bar{\boldsymbol{\omega}}_i - \hat{\ }\boldsymbol{\omega}_{i\text{-}1})$ 分别为估计的线性加加速度和角加速度。与 $\hat{\ }\mathbf{p}_i$ 和 $\hat{\ }\mathbf{q}_i$相对应的齐次变换集合 $\hat{\ }\mathbf{T}_i^{\mathcal{W}} \in \mathbb{SE}(3)$，定义了扫描过程中的粗略离散时间轨迹。随后，从最近的前序变换到每个点 p_k^n 的解析连续时间解，可恢复该点特定的去畸变变换 $\hat{\ }\mathbf{T}_n^{\mathcal{W}*}$ ，使得

$$\begin{aligned}
\hat{\mathbf{p}}^*(t) &= \hat{\mathbf{p}}_{i\text{-}1} + \hat{\mathbf{v}}_{i\text{-}1}t + \tfrac{1}{2}\hat{\mathbf{R}}(\hat{\mathbf{q}}_{i\text{-}1})\hat{\boldsymbol{a}}_{i\text{-}1}t^2 + \tfrac{1}{6}\hat{\boldsymbol{j}}_i t^3\,,\\
\hat{\mathbf{q}}^*(t) &= \hat{\mathbf{q}}_{i\text{-}1} + \tfrac{1}{2}(\hat{\mathbf{q}}_{i\text{-}1}\otimes\hat{\boldsymbol{\omega}}_{i\text{-}1})t + \tfrac{1}{4}(\hat{\mathbf{q}}_{i\text{-}1}\otimes\hat{\boldsymbol{\alpha}}_i)t^2\,,
\end{aligned} \tag{6}$$

其中 $i\text{-}1$ 和 i 分别对应时间上最接近的前一条和后一条IMU测量值， t 是点 p_k^n 与时间上最接近的前一条 IMU测量值之间的时间戳，而 $\hat{\ }\mathbf{T}_n^{\mathcal{W}*}$ 是与 $\hat{\ }\mathbf{p}^*$ 和 $\hat{\ }\mathbf{q}^*$ 对应的变换，适用于 p_k^n （图4）。注意， （6）仅由 t 参数化，因此可以查询任意所需时刻的变换，以构建连续时间轨迹。

这一两步流程的结果是一个运动校正点云，它也与 $\mathcal{W}$ 中的地图近似对齐，因此天然包含了用于广义迭代最近点的优化先验（第 IV-C节）。重要的是， （5）和（6）的效果取决于$\hat{\ }\mathbf{v}_0^{\mathcal{W}}$ （速度的初始估计）、$\mathbf{b}_k^a$ 和 $\mathbf{b}_k^{\omega}$（惯性测量单元偏置的估计）的准确性，以及运动校正时准确的初始机体姿态 $\hat{\ }\mathbf{q}_0$ （以正确补偿重力向量）。因此我们强调，若扫描匹配能够返回准确解，那么我们方法可靠性的关键在于，借助非线性几何观测器 保证这些项全局收敛 。 [42],

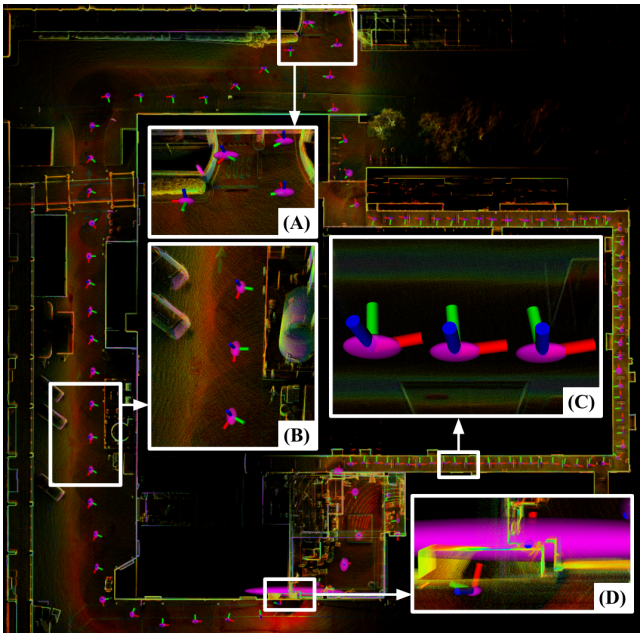


图 5. **传感器无关退化**。 使用我们在（A 和 B）室外环境、 （C）狭窄走廊以及（D）穿过门口时计算的广义退化度量，为每个关键帧生成的不确定性椭球（紫色）。我们的度量具有全局性，即椭球在室内和室外环境中的尺寸一致；同时也与传感器无关，因为它考虑了点云密度（不同激光雷达传感器和体素化叶片尺寸下的点云密度可能不同）。请注意，这些椭球通常只有毫米级，但为便于可视化而进行了放大。

IV. 鲁棒且具感知能力的定位

A. 基于传感器无关退化的抗滑移关键帧选取

（10）在 GICP 平面对平面配准中，当对应关系稀疏或不足时，可能会收敛到次优局部极小值。此类较弱的数据对应关系随后可能导致定位不佳或发散，因为估计值会“逃离”局部极小值附近的浅梯度区域。这种现象通常称为激光雷达滑移，常发生在周围环境缺乏特征或存在几何退化（例如长隧道或大型场地）时，其原因是源点云与目标点云之间的数据关联不正确。在 基于关键帧的 激光惯性里程计中，当提取的子地图无法充分表示周围环境时，也可能出现约束不足的优化问题，从而导致用于扫描到地图匹配的数据对应关系数量较少。当环境发生突变（例如穿过一扇门或走上楼梯间），但附近没有能够描述新环境的关键帧时，就可能出现这种情况。尽管以往工作使用Hessian矩阵的条件数 [2], [36], [37]来识别环境退化，使得 $\kappa(\mathbf{H_{tt}}) = |\lambda_{\max}(\mathbf{H_{tt}})|/|\lambda_{\min}(\mathbf{H_{tt}})|$，但该度量仅能告知系统问题中约束最强与最弱方向之间的相对滑移程度。条件数会受到环境规模和点密度的影响，因此，更稳健的方法是针对不同规模的环境和传感器配置，计算更加一致的退化度量。这样便可得到一种全局且与传感器无关的度量

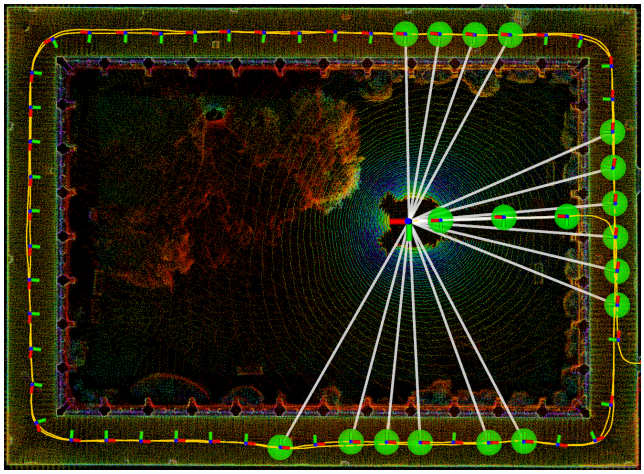


图6. **基于 Jaccard 指数的子地图构建**。 使用 Newer College 数据集扩展版（回廊集合）为扫描到地图阶段生成子地图 2 [43]。对于每次新获取的扫描，我们计算其与每个环境关键帧（坐标轴）的 Jaccard 指数，并仅提取与当前扫描具有显著重叠度的关键帧（绿色圆圈和白色线条）。随后，将与这些重叠关键帧相关联的点云及其内存中的协方差进行拼接，以实现精确的扫描到地图配准。在此示例中，使用的重叠度阈值至少为 20% 。

我们利用该度量来检测何时应向环境中插入新的关键帧。

令 $\mathcal{C}$ 为 $\hat{}\,\mathcal{P}_k^{\mathcal{W}}$ 与 $\hat{}\,\mathcal{S}_k^{\mathcal{W}}$ 之间所有对应点的集合，因此 $|\mathcal{C}|$ 为对应点的总数；令 $\mathcal{E}$ 为此前在式（10）中所述的非线性最小二乘求解器（例如 Levenberg-Marquardt）收敛后所有对应关系的总误差。此外，令 $\mathrm{H} \in \mathbb{R}^{6x6}$ 为广义迭代最近点的 Hessian矩阵，$\mathbf{H_{tt}} \in \mathbb{R}^{3x3}$为 H 的平移部分对应的子矩阵，其特征值为 $\lambda_{\max}(\mathbf{H_{tt}}) \geq \cdots \geq \lambda_{\min}(\mathbf{H_{tt}})$，用于提供非线性优化收敛后的局部梯度信息。注意，为提高计算效率，$\mathrm{H} \approx \mathrm{J}^{\top}\mathrm{J}$，且 J 为 Jacobian矩阵。于是，系统的全局退化度 d_k 为对各特征值 $\lambda(\mathbf{H_{tt}})$缩放后的最大值，使得

$$d_k = \max\left[\frac{m_k^2}{\lambda(\mathbf{H_{tt}})\sqrt{z_k}}\right], \tag{7}$$

其中 m_k 计算得到的宽敞度 [20]，定义为 $m_k = \alpha m_{k-1} + \beta M_k$，其中 M_k 是从原点到预处理点云中每个点的欧氏点距离中位数（常数 $\alpha = 0.95$、$\beta = 0.05$），而 z_k 是点云的稀疏度，如上文（11）所定义。每个传入的扫描都会计算其退化程度，并将其保存在内存中，供每个新关键帧使用。如果当前退化程度与前一个关键帧所在位置的退化程度之差足够大，就会插入一个新的关键帧，为扫描到地图模块提供新的信息。

式（7）背后的直觉在于，每个缩放因子（即m_k 和 z_k）如何影响 λ（$\mathbf{H_{tt}}$）。具体而言，计算条件数 κ（$\mathbf{H_{tt}}$）可以帮助判断局部梯度的椭圆程度（从而判断收敛到局部最小值可能需要多长时间），但梯度细长并不一定意味着即将发生因约束不足导致的滑移。换言之， κ（$\mathbf{H_{tt}}$）是一种相对指标，用于衡量优化问题受到约束的程度，因为它仅计算最陡方向与最平缓方向之间的相对比值。为了更准确地判断何时可能发生滑移，式（7）直接考察每个特征值的倒数。通过 z_k，对提供较少环境信息的传感器给予奖励，并对较大的环境施加惩罚，因为测量精度会随着距离增加而降低；这些缩放因子使 d_k 在不同传感器和不同大小的环境中更具一致性，从而实现更可靠的滑移检测指标（图5）。

B. 通过三维杰卡德指数生成子地图

DLIOM 算法的一项关键创新，在于它如何明确地为扫描到地图配准生成基于关键帧的子地图。理想情况下，应将所有已观测点的完整历史记录用于匹配，以确保扫描匹配过程中不会缺少重要的环境信息。然而，由于要与如此庞大的地图进行对齐所需的最近邻运算数量极其庞大，这在计算上完全难以实现。以往方法要么简单地假设地图空间中距离最近的点最相关，要么通过关键帧空间中的最近邻和凸包提取，隐式计算关键帧相关性 [20],我们提出一种生成局部子地图的新方法，通过计算当前扫描与每个关键帧之间的*Jaccard* 指数 [44]，明确地最大化当前扫描与子地图之间的覆盖范围。

令两个点云 $\mathcal{P}_1 \cap \mathcal{P}_2$ 的交集为集合 $\mathcal{C}_{1,\,2}$，其中包含两个点云在公共参考坐标系下的所有对应点（距离在一定范围内），因此令$|\mathcal{C}_{1,\,2}|$ 表示对应点的总数。此外，令两个点云 $\mathcal{P}_1 \cup \mathcal{P}_2$ 的并集定义为集合$\mathcal{U}_{1,\,2}$，其中包含两个点云中所有不相交的点，以及$\mathcal{C}_{1,\,2}$中每对对应点的均值，使得$\mathcal{U}_{1,\,2}$ 中的点总数等于

$$|\mathcal{U}_{1,2}| = (|\mathcal{P}_1| \oplus |\mathcal{P}_2|) \setminus |\mathcal{C}_{1,2}|\,. \tag{8}$$

然后，对于时刻 k 新获取的每次激光雷达扫描，我们计算该扫描 $\hat{}\,\mathcal{P}_k^{\mathcal{W}}$ 与每个j^{th} 关键帧 $\mathcal{K}_j^{\mathcal{W}}$ 之间的三维杰卡德指数，定义如下：

$$J(\hat{\mathcal{P}}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}}) = \frac{|\hat{\mathcal{P}}_k^{\mathcal{W}} \cap \mathcal{K}_j^{\mathcal{W}}|}{|\hat{\mathcal{P}}_k^{\mathcal{W}} \cup \mathcal{K}_j^{\mathcal{W}}|}, \tag{9}$$

或者换言之，它相当于 3D 领域中的“交并比”相似度度量。如果 $J(\hat{}\,\mathcal{P}_k^{\mathcal{W}}, \mathcal{K}_j^{\mathcal{W}})$ 超过了 j^{th} 关键帧的设定阈值（即该关键帧足够相似），则会将其纳入子地图，用于扫描到地图配准。与以往通过一系列启发式规则构建子地图的方法不同（例如，直接检索当前位置一定半径范围内的局部点，或假定附近的关键帧包含相关点），我们的方法会显式计算每个关键帧与.....的相关性。

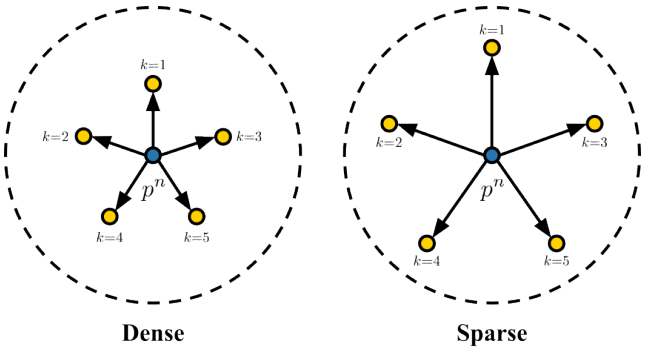


图 7. **通过点云稀疏度进行自适应扫描匹配。** 对于每个经过运动校正的点云，我们计算其稀疏度，定义为 K 个最近邻之间（11）（K=5 在此示例中）的逐点欧几里得距离平均值。该指标用于缩放扫描到地图模块的最大对应距离，以进行自适应配准。在小尺度环境中的扫描包含的点彼此距离很近（左），因此较小的移动对点位移的影响较小。另一方面，在大尺度环境中，点分布得更为分散（右），因此 GICP 需要更大的搜索距离才能正确进行数据关联。

<escape>当前环境，以确保扫描到地图优化具有良好的约束条件，并使扫描数据与子地图之间达到最大覆盖范围。此外，仅使用与当前扫描具有显著重叠度的关键帧扫描，可确保在构建子地图的法向量或 k-d 树数据结构时不会产生任何无用操作（图6）。</escape>

C. 通过点云稀疏度进行自适应扫描匹配

通过同时校正运动畸变并将 GICP 优化先验纳入点云，DLIOM 可以直接执行扫描到地图配准，绕过以往方法所需的扫描到扫描配准。该配准被表述为一个非线性优化问题，旨在最小化当前扫描与提取的局部子地图之间对应点/平面的距离。设 $\hat{}\mathcal{P}_k^{\mathcal{W}}$ 为 $\mathcal{W}$ 中经过校正的点云，$\hat{}\ \mathcal{S}_k^{\mathcal{W}}$ 为提取的子地图。那么，扫描到地图优化的目标是找到一个变换 $\Delta\mathbf{T}_k$，使点云更好地对齐，其中

$$\Delta\hat{\mathbf{T}}_k = \underset{\Delta\mathbf{T}_k}{\arg\min}\ \mathcal{E}\left(\Delta\mathbf{T}_k\hat{\mathcal{P}}_k^{\mathcal{W}},\ \hat{\mathcal{S}}_k^{\mathcal{W}}\right), \tag{10}$$

使得GICP残差误差 $\mathcal{E}$ 定义为

$$\mathcal{E}\left(\Delta\mathbf{T}_k\hat{\mathcal{P}}_k^{\mathcal{W}},\hat{\mathcal{S}}_k^{\mathcal{W}}\right) = \sum_{c\in\mathcal{C}} d_c^{\top}\left(C_{k,c}^{\mathcal{S}} + \Delta\mathbf{T}_k C_{k,c}^{\mathcal{P}}\Delta\mathbf{T}_k^{\top}\right)^{-1} d_c\,,$$

对于时间步 k 时 $\hat{}\ \mathcal{P}_k^{\mathcal{W}}$ 与 $\hat{}\ \mathcal{S}_k^{\mathcal{W}}$ 之间的一组对应点 $\mathcal{C}$，$d_c = \hat{s}_k^c - \Delta\mathrm{T}_k\hat{}\,p_k^c$、$\hat{}\,p_k^c \in \hat{}\,\mathcal{P}_k^{\mathcal{W}}$、$\hat{s}_k^c \in \hat{}\,\mathcal{S}_k^{\mathcal{W}}$、$\forall c \in \mathcal{C}$ 以及 $C_k^{\mathcal{P}}{}_{,\,c}$ 和 $C_k^{\mathcal{S}}{}_{,\,c}$ 分别是点云 $\hat{}\ \mathcal{P}_k^{\mathcal{W}}$ 和子地图 $\hat{}\ \mathcal{S}_k^{\mathcal{W}}$ 的估计协方差矩阵。然后，根据 [9]，通过使用特征值为 (1, 1, ϵ) 的矩阵对协方差矩阵 $C_k^{\mathcal{P}}{}_{,\,c}$ 和 $C_k^{\mathcal{S}}{}_{,\,c}$ 进行正则化，将这种点到平面形式转化为平面到平面优化，其中 ϵ 表示表面法线方向上的低不确定性。由此得到的 $\hat{}\ \Delta\mathrm{T}_k$ 是一个最优校正变换，可更好地将经过先验变换的扫描 $\hat{}\ \mathcal{P}_k^{\mathcal{W}}$ 与子地图 $\hat{}\ \mathcal{S}_k^{\mathcal{W}}$ 进行全局对齐，从而使 $\hat{}\mathrm{T}_k^{\mathcal{W}} = \Delta\hat{}\mathrm{T}_k\hat{}\mathrm{T}_M^{\mathcal{W}}$（其中 $\hat{}\mathrm{T}_M^{\mathcal{W}}$ 是最后一个点的 IMU 积分）成为经过全局优化的机器人位姿

它用于地图构建，并作为非线性几何观测器的更新信号。

一个经常被忽略的重要参数是：在优化过程中，应将对应点或平面之间的最大距离设置为多少。用户通常通过手动调节来确定该参数，但为了保证一致性和计算效率，该参数应根据环境结构进行相应调整。例如，在小规模环境中（如实验室），激光雷达扫描中的点彼此距离更近，因此，即使发生微小移动，给定点的位移也较小。相比之下，在更开阔的环境中（如室外远处树木上的某个点），由于距离更远，同样的点在发生微小旋转时也会产生更大的位移，因此需要更大的搜索半径，以实现正确的对应匹配（图 7）。因此，我们根据当前扫描的“稀疏度”来设置 GICP 求解器在两个点云之间的最大对应搜索距离，其定义为 $z_k = \alpha z_{k-1} + \beta D_k$，其中

$$D_k = \frac{1}{|\mathcal{P}|N}\sum_{n=1}^{N} D_k^n \tag{11}$$

是每个点归一化后的稀疏度，D_k^n 是点 n到 K 个最近邻的平均欧几里得距离，$\alpha = 0.95$ 和 $\beta = 0.05$ 是用于生成z_k的平滑常数，z_k是设为最大对应距离的滤波信号。直观来说，这就是当前扫描中点间距离的平均值；环境越大，稀疏点（即距离更远的点）越多，从而使该数值增大。根据点的稀疏度调整对应距离，可以使扫描匹配在不同规模的环境中表现得更加一致。

D. 分层几何观测器

扫描到地图对齐所计算出的变换 $\hat{}\mathbf{T}_k^{\mathcal{W}}$ 与 IMU 测量值融合，通过一种新颖的分层非线性几何观测器生成完整的 $\hat{}$状态估计 $\mathbf{X}_k$。关于该观测器的完整分析见 [42],$\hat{}$，简而言之，可以证明$\mathbf{X}$ 在确定性条件下以最少的计算量全局收敛到 $\mathbf{X}$。证明利用收缩理论，首先证明四元数估计会指数收敛到真实四元数附近的一个区域。随后，姿态估计作为另一个收缩观测器的输入，用于估计平移状态。这种架构构成了一个收缩层级，能够保证估计值收敛到其真实值。该观测器具有很强的收敛性，这是相较于其他融合方案（例如滤波或位姿图优化）的主要优势；后者几乎不具备收敛保证。这一特性对于未来研究激光雷达里程计与建图流程优势的理论工作至关重要。从实践角度来看，该观测器能够实时生成平滑的估计值，因此其输出也适用于控制。本文使用的观测器是 [42]中的一个特例。

设 $\gamma_{\ell\in\{1,\ldots,5\}}$ 为正数，Δt_k^+ 为 GICP 位姿之间的时间间隔。如果传播位姿与

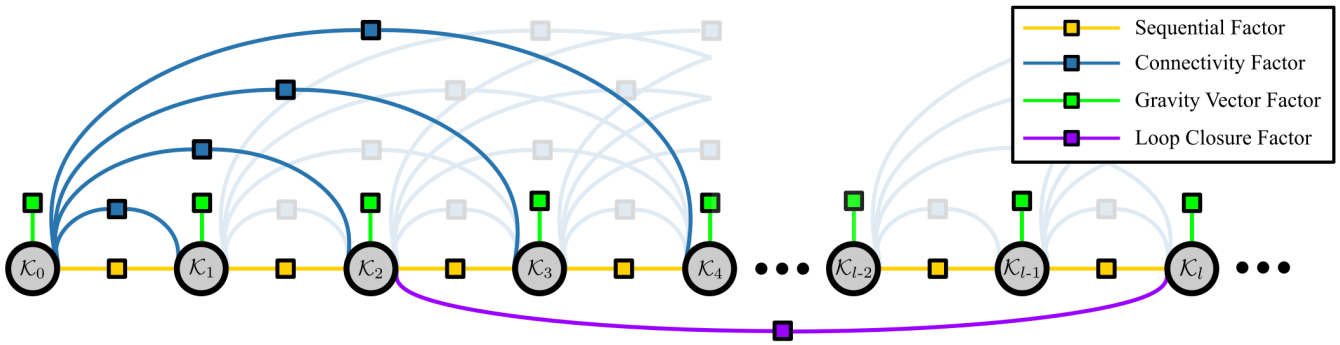


图 8。**基于关键帧的因子图建图**。我们的建图器会为每个新的关键帧在其因子图中添加一个节点，并通过顺序因子（黄色）、连通性因子（蓝色）、重力因子（绿色）或回环因子（紫色）添加相对约束。顺序因子以相邻关键帧之间的低不确定性为图提供强大的“骨架”，而连通性因子则根据关键帧对之间的重叠度进行缩放。经过纯里程计产生的长期漂移后，回环因子能够实现全局一致性。

测量位姿之间的误差为 $\mathbf{q}_e \coloneqq (q_e^\circ, \quad \vec{q}_e) = \hat{}\mathbf{q}_i^* \otimes \hat{}\mathbf{q}_k$ 和 $\mathbf{p}_e = \hat{}\mathbf{p}_k - \hat{}\mathbf{p}_i$，则姿态更新的形式为

$$\begin{aligned} \hat{\mathbf{q}}_i &\leftarrow \hat{\mathbf{q}}_i + \Delta t_k^+ \, \gamma_1 \, \hat{\mathbf{q}}_i \otimes \begin{bmatrix} 1 - |q_e^\circ| \\ \operatorname{sgn}(q_e^\circ)\, \vec{q}_e \end{bmatrix}, \\ \hat{\mathbf{b}}_i^{\boldsymbol{\omega}} &\leftarrow \hat{\mathbf{b}}_i^{\boldsymbol{\omega}} - \Delta t_k^+ \, \gamma_2 \, q_e^\circ \vec{q}_e \,, \end{aligned} \tag{12}$$

平移更新为

$$\begin{aligned} \hat{\mathbf{p}}_i &\leftarrow \hat{\mathbf{p}}_i + \Delta t_k^+ \, \gamma_3 \, \mathbf{p}_e \,, \\ \hat{\mathbf{v}}_i &\leftarrow \hat{\mathbf{v}}_i + \Delta t_k^+ \, \gamma_4 \, \mathbf{p}_e \,, \\ \hat{\mathbf{b}}_i^{\boldsymbol{a}} &\leftarrow \hat{\mathbf{b}}_i^{\boldsymbol{a}} - \Delta t_k^+ \, \gamma_5 \, \hat{\mathbf{R}}(\hat{\mathbf{q}}_i)^\top \mathbf{p}_e \,. \end{aligned} \tag{13}$$

请注意，状态校正具有层次性，因为姿态更新（12）与平移更新（13）完全解耦。此外，这是一个完全非线性的更新，因此能够保证状态估计足够准确，可以仅凭 IMU先验直接执行扫描到地图配准，而无需扫描到扫描配准。

V. 连通性建图

因子图广泛应用于同步定位与建图（SLAM），因为它是一种强大的工具，可通过位姿图优化 [13]融合各种模态的位姿估计，从而估计系统的完整状态。此类方法将相对位姿约束建模为最大后验（MAP）估计问题，并假设噪声服从高斯分布；通常将建图视为优化轨迹后的附带结果。然而，对于激光雷达扫描匹配和 IMU 预积分可能产生的复杂不确定性分布而言，这种单峰噪声模型过于简单。此外，用于里程计的基于图的优化几乎没有收敛保证，且传感器融合不一致时往往会导致严重的定位误差和地图变形。为此，我们使用因子图并非用于里程计（里程计由我们的几何观测器处理），而是用于显式表示环境。每收到一个关键帧（由 DLIOM 的里程计线程确定），便向图中添加一个新节点；节点间的各种因子有助于实现地图的全局一致性（图8）。除本节详述的因子外，我们还添加了一个重力因子，以局部约束每个关键帧的方向，具体如 [45]所述。

A. 连通性关键帧因子

因子图中节点间的相对约束通常按顺序添加（即在 [13]相邻节点之间添加因子），但非相邻关键帧之间的关系可以为图提供额外信息，有助于生成更准确且全局一致性更好的地图。这些额外约束称为连接因子，它们由在 $\mathcal{W}$ 中计算出的重叠度足够高的关键帧对确定，计算方法见第 IV-B节。也就是说，对于K 个关键帧， $K_i^{\mathcal{W}}$与 $K_j^{\mathcal{W}}$之间的连通性定义为三维杰卡德指数（9），并编码在对称矩阵 $\mathbf{C} \in \mathbb{R}^{K \times K}$中，使得

$$\mathbf{C}_{ij} = \begin{cases} \dfrac{|\hat{\mathcal{K}}_i^{\mathcal{W}} \cap \mathcal{K}_j^{\mathcal{W}}|}{|\hat{\mathcal{K}}_i^{\mathcal{W}} \cup \mathcal{K}_j^{\mathcal{W}}|} & \text{for } i > j \\ \dfrac{|\hat{\mathcal{K}}_j^{\mathcal{W}} \cap \mathcal{K}_i^{\mathcal{W}}|}{|\hat{\mathcal{K}}_j^{\mathcal{W}} \cup \mathcal{K}_i^{\mathcal{W}}|} & \text{for } i < j \\ 1 & \text{for } i = j \end{cases} \tag{14}$$

其中，对角线根据（9）的定义包含所有 1。当 $\mathbf{C}_{ij}$ 高于设定阈值时，会在两个关键帧之间添加一个新因子，该因子的噪声计算为$\zeta(1-\mathbf{C}_{ij})$，其中 ζ 是一个可调缩放参数，用于控制环境图的强度（见图 9）。

B. 基于关键帧的回环闭合

理想情况下，位置识别模块会搜索所有已观测数据以寻找回环闭合，并据此添加相应的图因子。然而，存储所有历史扫描在计算上不可行，因此扫描数据会以增量方式作为关键帧存储在内存中。从这个角度来看，这些关键帧可以理解为所有历史点云的一个子集，它最大限度地包含了有关环境的信息，并包含关于最重要位置的数据。然而，单次扫描可能相当稀疏（取决于所选传感器），且可能没有足够的点用于数据关联，无法通过扫描匹配进行准确检测。因此，我们不逐一遍历所有关键帧，也不重复使用由前端构建、仅针对里程计进行优化的子地图，而是[23], 构建一个额外的子地图，专为后端建图器优化，其中包含所有候选回环闭合关键帧。

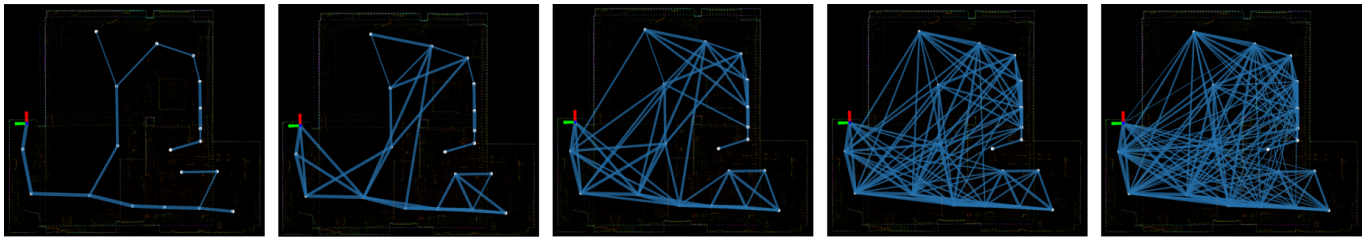


图 9. **环境连通性**。通过降低连接因子的阈值来增强图强度的示例（从左到右）。弱图（左）局部精度较低，但在向图中添加闭环时具有更大的灵活性；强图（右）由于具有更多根据关键帧间重叠度计算的关键帧间因子，因此局部精度更高。

按照上述方法将新的关键帧及其相关连通性约束添加到因子图后，在优化之前，我们通过一个三步过程搜索并执行闭环检测。首先，提取位于当前 位置一定半径范围内的关键帧，以及与当前关键帧存在一定重叠度的关键帧。随后，将对应的点云拼接成一个闭环点云 $\mathcal{L}_k^{\mathcal{W}}$并变换回 $\mathcal{R}$，然后在该点云与新的关键帧之间执行 GICP 扫描匹配。如果 $\hat{} \mathcal{K}_k^{\mathcal{R}}$与 $\mathcal{L}_k^{\mathcal{R}}$之间的适应度分数足够低（即所有对应点的平均欧氏误差较小），则在当前关键帧与用于构建闭环点云的 $\mathcal{W}$ 中距离最近的关键帧之间添加一个新的闭环因子。至关重要的是，配准过程采用一个先验值进行初始化，该先验值等于这两个关键帧在 $\mathcal{W}$ 中的距离，并设置足够大的平面到平面搜索距离。由于无需重新构建 GICP 所需的协方差，而是直接拼接各个关键帧的法向量，因此这一过程速度很快[20]。这种为闭环检测重建子地图的思路，可以轻松扩展到使用其他位置识别模块（例如 [39], [40]），以进一步提高鲁棒性。

VI. 算法实现

本节重点介绍面向小型轻量平台的系统实现中的三个重要细节：传感器时间同步、用于保持计算负载一致性的资源管理，以及与速度一致的闭环。

A. 传感器同步

时间同步是里程计算法中的一个关键环节，这些算法使用的传感器都具有各自的内部时钟。这一点十分必要，因为它能够通过基于时间的数据关联，使惯性测量单元测量值与激光雷达扫描在时间上保持对齐。DLIOM中存在三个时钟源，分别对应激光雷达、惯性测量单元和处理计算机。基于硬件的时间同步——即通过外部信号触发激光雷达扫描的采集——与现有的旋转式激光雷达不兼容，因为启动和停止旋转组件可能导致数据采集和时间记录不一致。因此，我们开发了一种基于软件的方法，用于补偿激光雷达（惯性测量单元）时钟与处理计算机时钟之间的偏差。当接收到第一个激光雷达（惯性测量单元）数据包时，处理计算机会记录其当前时钟时间 ${}^{c}t_0$ 以及传感器上进行该次测量的时间 ${}^{s}t_0$。随后，每个后续的 k^{th} 测量值相对于处理计算机时钟的时间为 ${}^{c}t_k$ ${}^{c}t_k = {}^{c}t_0 + ({}^{s}t_k - {}^{s}t_0)$，其中${}^{s}t_k$ 是传感器上采集该测量值的时间。尽管这种方法无法观测到通过线路发送第一条测量数据时产生的传输延迟，但在实践中效果良好。其性能令人满意，归因于使用经过的传感器时间来计算补偿后的测量时间，因为传感器时钟通常比处理计算机时钟更准确。

B. 子地图多线程

快速且一致的计算时间对于确保传入的激光雷达扫描不会被丢弃至关重要，尤其是在资源受限平台上。为此，DLIOM 将与当前扫描并非立即相关的工作卸载到单独的线程中；该线程在处理后续传入扫描时，仅会对其父线程造成极小干扰。因此，主点云处理线程的计算时间更短且更加稳定。次线程构建用于扫描匹配的局部子地图 k-d树，并构建与每个关键帧对应的、子地图所需的数据结构。通过将每个关键帧计算得到的 k-d树保存在内存中，可以快速计算每个关键帧的 Jaccard指数，从而使子地图构建过程进一步提速；这一过程与隐式最近邻关键帧搜索相比几乎没有差异。该线程可以随时完成，而不会影响 DLIOM 接收新激光雷达扫描的能力。此外，它会定期检查主线程是否正在运行，以便暂停自身并释放高度并行化扫描匹配算法可能需要的资源。关键在于，子地图的变化速度远低于激光雷达传感器频率，并且新子地图的构建没有严格的截止时间。因此，该线程偶尔使新子地图延迟若干次扫描迭代所造成的影响微乎其微，不会显著影响性能。

C. 速度一致的闭环

尽管我们的里程计模块会构建一个由相关关键帧组成的子地图，但这些关键帧直接取自全局优化地图。因此，在闭环检测后更新状态和关键帧时必须谨慎。具体而言，地图中的估计位置会瞬间跳变，但连续 轨迹有利于控制，且所需的更新次数更少。

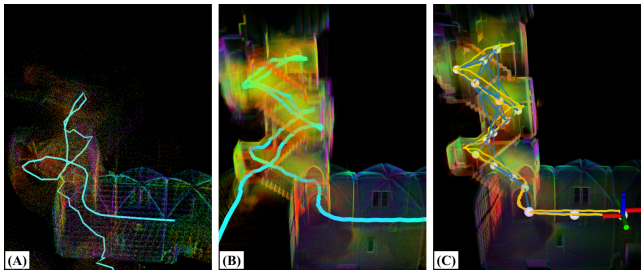


图 10. **抗滑定位**。 使用 Newer College 扩展版楼梯数据集生成的地图和轨迹对比：(A) LIO-SAM [13], (B) FAST-LIO2 [21], 和 (C) 我们的方法 [43]。对于 (A)，我们观察到进入楼梯间后立即发生了滑移；对于 (B)，上升过程中跟踪不断抖动（例如，地图模糊），下楼到底部后则发生滑移。对于 (C)，我们的关键帧布置（白色节点）使算法在上升和下楼过程中都能充分跟踪，从而构建出清晰的地图和准确的轨迹。

在里程计模块中。因此，我们允许建图模块执行此即时更新，并在地图 坐标系中维护机器人位姿，同时相对于里程计 坐标系建立偏移，使机器人位姿和最新关键帧位姿不会发生跳变。更新后，发生偏移的关键帧必须在里程计模块中对其点云进行变换；此操作由后台线程执行，并优先处理子地图关键帧。

七、实验结果

在本节中，我们首先分析每项提出的贡献，以使读者相信，我们的核心创新对于提高定位与建图的精度和鲁棒性是合理且有效的。随后，为了验证我们的方法和整个系统，我们将 DLIOM 的精度和效率与当前几种最先进的开源系统进行了比较。这些系统包括三种激光里程计算法，即 DLO [20], CT-ICP [46], 和 KISS-ICP [35], ，以及三种激光惯性里程计算法，即 LIO-SAM [13], FAST-LIO2 [21], 和 DLIO [6]。我们使用两个公开基准数据集的全部数据，以及一个在大学校园周边自行采集的数据集，对这些算法进行比较。这些基准数据集包括 Newer College 数据集 [47] 和 Newer College 扩展数据集 [43]。值得注意的是，由于某些知名算法（例如 Wildcat [30]和 X-ICP [5]）采用闭源实现，和/或使用了尚未公开的自定义数据集，因此无法对其进行全面比较。不过，我们使用 MulRan DCC03 数据集 [48]对 Wildcat [30] 进行了简要评估，因为其论文中提供了该数据集的数值结果。最后，我们展示了如何在实验室环境中，使用我们定制的航空平台，通过执行一系列高强度自主机动，实现 DLIOM 的全闭环飞行应用。

A. 组件分析

1) 抗滑移关键帧选取：为展示我们的抗滑移关键帧选取策略的稳健性——该策略会持续监测扫描匹配的最优性，并在滑移刚开始时放置环境关键帧——我们使用 NewerCollege Extension-Stairs 数据集 [43] ，并与 LIO-SAM [13] 和 FAST-LIO2 [21]进行比较。楼梯

表 I 子地图构建策略比较 [48]

子地图构建策略	绝对轨迹误差 [m]		
	Max	Mean	RMSE
NN + 凸 [20]	0.5898	0.0923 ± 0.444	0.1006
Jaccard指数	**0.2613**	**0.0604 ± 0.0361**	**0.0546**

因传感器在 Z 方向的视场有限，楼梯对于 SLAM算法而言向来极具挑战性，尤其是以激光雷达为核心的算法。在上楼过程中，可用于关联的数据点较少，因此跟踪可能会很困难。图10中可以观察到这一现象。对于 LIO-SAM，算法在楼梯间入口处便发生了滑移，这很可能是因为算法所依赖的特征提取缺乏足够的特征。对于 FAST-LIO2，跟踪效果要好得多（该算法同样不进行特征提取），但在顶点附近定位不稳定（例如，顶部的地图模糊不清），并且算法在下楼过程中完全发生了滑移。然而，通过检测滑移的开始，DLIOM 可以主动放置新的关键帧，持续锚定自身在空间中的位置，从而实现在具有挑战性的场景中跟踪。图 1(D) 进一步展示了这一点：我们的方法能够跟踪通过八段楼梯梯段，而所有其他算法均告失败。

2) 杰卡德子地图构建：我们提出的子地图构建策略会通过计算三维杰卡德指数，直接计算每个环境关键帧的相关性（即重叠度），随后提取最适用于扫描匹配的关键帧。我们将该策略与一种朴素的隐式方法进行比较。具体而言，朴素方法会提取空间位置相近的关键帧，以及构成关键帧凸包的关键帧。该策略最初由 [20],提出，它隐含地假设这些关键帧最适合用于对当前扫描进行全局配准。然而，如表I所示，在使用 Newer College Extension - Cloister数据集（图6）比较朴素方法（“NN + Convex”）与我们的杰卡德方法（“Jaccard Index”）的轨迹误差时可以看到，这种方法可能无法提取最适合扫描到地图配准的子地图，并且会降低精度、增加计算复杂度。通过启发式方法提取此类关键帧，可能会用到实际扫描到地图过程中并未使用的点云，因而在构建 k-d树或协方差结构时增加不必要的操作。相比之下，明确提取最有用的关键帧，可以为扫描到地图配准提供更实用的关键帧集合，最终有助于 GICP 的数据关联，并减少在可能完全不会用于配准的关键帧上浪费的计算时间。这适用于所有场景，例如上楼梯时，附近的关键帧可能完全没有重叠度，但最近邻方法仍会将其提取出来。

3) 连通性建图：最后，我们验证了在因子图建图器中为关键帧之间添加连接因子的有效性。这些因子在重叠节点之间提供了额外约束，从而更好地对彼此之间的每个关键帧施加局部约束，这有助于

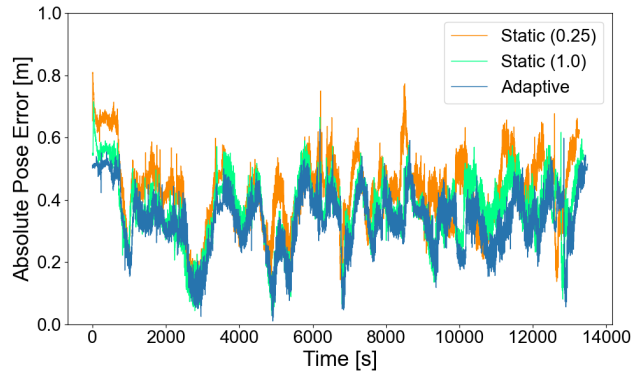


图 11。**自适应扫描匹配**。使用自适应和静态扫描匹配对应阈值，在 Newer College - Short Experiment 数据集上对绝对位姿误差进行比较。我们观察到，与其他方法通常采用的静态搜索阈值相比，使用我们的自适应缩放技术平均可获得更低的轨迹误差；这使得系统在小型和大型环境中都能实现更加稳定的定位。

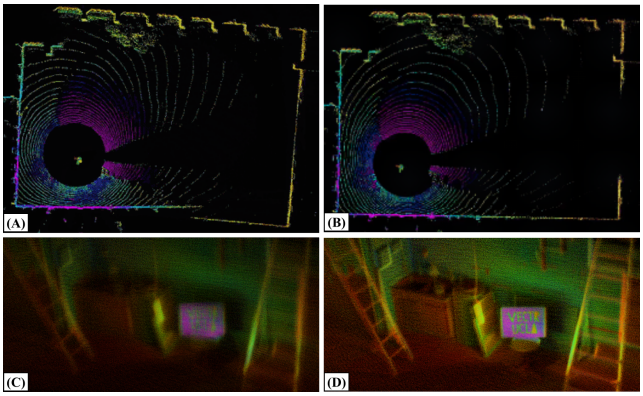


图 12。**运动校正**。快速运动造成的畸变会严重扭曲激光雷达扫描，从而影响扫描匹配（进而影响定位）的准确性。（A）来自 Newer College - Dynamic 数据集的点云存在严重畸变，导致底部墙壁无法对齐。（B）使用我们的由粗到精方案进行运动校正后的点云，能够准确重建环境。在我们方法的输出地图中也能观察到这一现象：未经运动校正时，由剧烈运动生成的地图（C）比经过运动校正生成的地图（D）更加模糊。

回环闭合后的建图精度。我们比较了两种地图与真实值之间的整体点云间距离：一种是通过关键帧之间的连通性因子生成的地图，另一种则仅通过顺序（类似“里程计”）因子生成。该实验使用了 Newer College Extension - Maths（H）数据集，真实值由高精度 Leica BLK360 激光扫描仪提供。点云间误差使用 CloudCompare 应用程序计算 [49]，并在手动配准后进行比较。所有点云均采用叶片尺寸为 0.1m 的体素化处理，以确保比较公平；同时，将计算平均误差的最大阈值设为 1m，以过滤不重叠区域。在不使用连接因子的情况下，DLIOM 的输出地图与真实值之间的平均点云间距离为 0。3285 ± 0.2289；然而，使用连接因子后，该点云间距离降低至 0.2982± 0.2214。这些重叠节点之间的连接因子能够为闭环提供额外的约束，从而通过图优化生成更加精确的地图。

4) 自适应扫描匹配：接下来，我们将自适应扫描匹配技术与两个静态设定的阈值进行了比较。该技术会根据扫描稀疏度缩放广义迭代最近点的最大对应距离。具体而言，我们将其与静态对应距离0.25进行了比较；该值通常在较小的环境中最优（因为点之间距离更近）。我们还将其与静态对应距离1.0所生成的轨迹进行了比较；对于较大的室外环境，该值更为合理。本次比较采用 Newer College - Short Experiment 数据集，其中包含三个大小各异的区域（“Quad”、“Mid-Section”和“Parkland”）。结果如图 11所示。我们观察到，自适应阈值方案表现最佳，其次是静态阈值1.0，而阈值0.25 的表现则是三者中最差的。这是合理的，因为短程实验数据集的大部分场景属于中型和大型场景（“Quad”和“Parkland”），而较小的“Mid-Section”场景约占轨迹的 20%。因此，较大的阈值平均而言会比小阈值表现更好（均方根误差为 0。3810 ±0.1063，而小阈值为 0。4140 ± 0.1167），但仍不及能够自适应地兼顾两者优点的方案（0。3571 ± 0.0971）。

5) 运动校正比较：为研究所提出运动校正方案的影响，我们首先使用 Newer College 数据集 [47]开展了不同程度去畸变的消融研究。每种受测算法采用不同程度和方式的运动补偿，因此构成了与当前最先进方法的全面比较。为单独评估相较于先前工作新增的部分，本研究使用了 DLIO [6]，其运动校正方式从完全不进行校正（无），到仅通过最近一次 IMU 积分进行校正（5）（离散），再到同时通过（5）和（6）进行完整的连续时间运动校正（连续）（表II）。尤其值得注意的是 Dynamic 数据集，其中包含极为剧烈的运动，旋转速度最高可达 3.5 rad/s。未进行校正时，其误差在所有算法中最高，均方根误差为 0.1959 。采用部分校正后，由于扫描匹配使用了更准确、更具代表性的点云，误差显著降低；然而，使用完整的所提方案时，我们观察到误差仅为0.0612 均方根误差，是所有受测算法中最低的。其他所有数据集也呈现类似趋势，运动校正改善后带来的卓越跟踪精度显而易见：在连续时间内构建唯一变换，能够生成比以往方法更真实的点云，进而影响扫描匹配和轨迹精度。图 12 通过实验展示了这一点：与采用简单运动校正或完全不进行运动校正的方法相比，我们的由粗到细技术所构建的点云能够更准确地表示环境。

B. 基准测试结果

我们使用公开数据集和自行采集的数据集，将 DLIO M 的精度和效率与六种最先进的算法进行比较。除外参外，所有实验均采用各算法在撰写本文时的默认参数，除非另有说明。具体而言，为使 LIO-SAM 获得最佳结果，我们保持回环闭合启用；为使 FAST-LIO2 获得最佳结果，则禁用在线外参估计。

表 II 与 Newer College 数据集的比较 [47]

算法	Type	绝对轨迹误差（均方根误差） [米]					平均值计算 [ms]
		短时实验	长时实验	带动态场景的四旋翼	动态旋转	Parkland Mount	
		1609.40米	*3063.42 米*	*479.04m*	*97.20m*	*695.68m*	
DLO [20]	LO	0.4633	0.4125	0.1059	0.1954	0.1846	48.10
CT-ICP [46]	LO	0.5552	0.5761	0.0981	0.1426	0.1802	412.27
KISS-ICP [50]	LO	0.6675	1.5311	0.1040	失败	0.2027	167.38
LIO-SAM [13]	LIO	0.3957	0.4092	0.0950	0.0973	0.1761	179.33
FAST-LIO2 [21]	LIO	0.3775	0.3324	0.0879	0.0771	0.1483	42.86
DLIO (无)	LIO	0.4299	0.3988	0.1117	0.1959	0.1821	34.88
离散直接激光惯性里程计	LIO	0.3803	0.3629	0.0943	0.0798	0.1537	**34.61**
连续直接激光惯性里程计 [6]	LIO	0.3606	0.3268	0.0837	0.0612	0.1196	35.74
DLIOM	LIO	**0.3571**	**0.3252**	**0.0821**	**0.0609**	**0.1181**	36.21

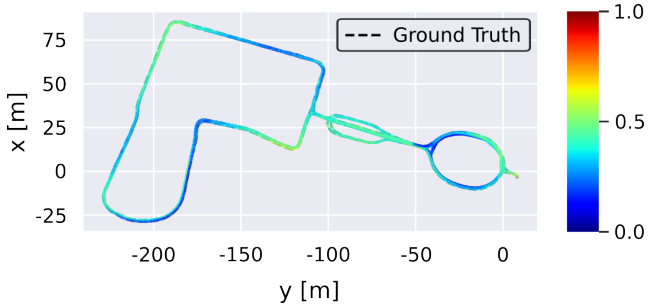


图 13。**长程实验的轨迹**。Newer College 长程实验生成的轨迹。颜色表示绝对位姿误差。

对于 FAST-LIO2，我们缩小了默认裁剪范围，否则它在较小的环境中会失效。KISS-ICP 启用了去畸变；对于 CT-ICP，我们增大了体素化分辨率，并将数据回放速度降至 25%，否则该算法会因大量帧丢失而失效。为进行更公平的评估，我们禁用了 DLIOM 的回环闭合。对于所有公开基准数据集，我们使用 evo [51] TUM [52] 格式将轨迹与真实值进行比较，并使用 Umeyama 算法 [53] 进行对齐。未能产生有意义结果的算法会在表格中作相应标注；每个数据集的轨迹长度则以斜体标出，让读者了解其持续时长。所有测试均在一台配备 16 核 Intel i7-11800H CPU 的计算机上进行。

1) Newer College 数据集：我们还使用原始 Newer College 基准数据集 [47]，比较了所有算法的轨迹精度和平均单次扫描耗时。在这些测试中，除 Ouster OS1-64（10Hz）提供的数据外，我们还使用其内置惯性测量单元（100Hz）提供的数据，以确保传感器之间的时间同步准确。对于某些 Newer College 数据集，为了进行公平比较，计算 FAST-LIO2 的均方根误差时排除了前 100 个位姿，因为起始阶段出现了滑移。Short、Long 和 Parkland 实验的路线是在不同区域以正常步行速度采集的，而 Quad 和 Dynamic 则包含快速的线性运动和角运动。结果如表II所示，我们观察到，与所有其他算法相比，我们的方法取得了最低的轨迹均方根误差。图13 展示了在行进超过三公里后，DLIOM 在 Newer College - Long 实验数据集上仍保持较低的轨迹误差，与真实值十分接近。

2）Newer College 扩展数据集：此外，我们使用 Newer College 基准数据集的最新扩展版本对所有算法进行了比较 [43]，该扩展包含三个数据集合。集合 1 和 3 各包含三个数据集，难度逐步增加：从运动速度较慢的“简单”（E），到包含稍为激进的转向速率和运动的“中等”（M），最后到包含高度激进的运动、旋转，以及位于小型和大型环境中的位置变化的“困难”（H）。集合 2 包含三个数据集，每个数据集与其他数据集都有显著差异，从而构成多样化的环境。这些环境包括上下楼梯、在能见度有限的回廊中行走，以及在包含多个环路的大型公园中行进。在该基准数据集中，我们使用了 Ouster OS0-128（10Hz）和 Alphasense Core IMU（200Hz）的数据，因为这一特定扩展版本的数据具有良好的同步性。

所有测试算法的结果如表 III所示。尤其值得注意的是两个困难（H）数据集以及 Stairs 数据集。对于 Quad（H）和 Maths（H），由于两者都存在极其剧烈且不可预测的运动，CT-ICP 失败了（即使将播放速度降至 10%），而 DLO 和 KISS-ICP 的轨迹误差都显著更高。这证明了融合惯性测量单元进行点云运动校正的优势及必要性。对于 Stairs，由于上升过程十分困难，以及激光雷达传感器的垂直视场有限，大多数算法都无法产生有意义的结果。在能够进行充分跟踪的算法中，DLO 和 DLIO 的误差都显著较高；然而，通过在滑移开始时检测并放置新的关键帧，DLIOM 能够实现仅 0.0686m 的低均方根误差。这一点在图 10 中也有进一步说明。

表 III 与 Newer College 扩展数据集的比较 [43]

算法	Type	绝对轨迹误差（均方根误差） [米]									平均值计算 [ms]
		四边形（E）	四边形（M）	Quad（困难）	楼梯	回廊	Park	数学（E）	数学（M）	数学（困难）	
		*246.67*米	*260.36* 米	*234.81*米	*57.04* 米	*428.79*米	*2396.20*米	*263.62*米	*304.28*米	*320.56*米	
DLO [20]	LO	0.0866	0.1141	0.1490	0.1605	0.1608	0.8108	0.1658	0.7730	1.0864	31.34
CT-ICP [46]	LO	0.0974	0.1820	失败	失败	0.3558	0.7935	0.0970	0.1362	失败	213.41
KISS-ICP [50]	LO	0.0960	0.2016	0.3663	失败	0.7398	0.9631	0.0718	0.1203	0.2789	62.38
LIO-SAM [13]	LIO	0.0714	0.0718	0.0909	失败	0.0811	0.8371	0.0784	0.1168	0.0932	51.57
FAST-LIO2 [21]	LIO	0.0491	0.0608	0.0670	失败	0.0594	0.2678	0.0872	0.1024	0.0646	28.04
DLIO [6]	LIO	0.0388	0.0610	0.0631	0.1559	0.0855	0.2866	0.0786	0.0983	0.0863	**25.99**
DLIOM	LIO	**0.0350**	**0.0571**	**0.0615**	**0.0686**	**0.0546**	**0.2608**	**0.0609**	**0.0904**	**0.0609**	27.89

表 IV 与 MulRan DCC 的比较03 [48]

算法	相对轨迹误差（RPE）	
	平移 [%]	旋转 [°/m]
LIO-SAM [13]	**2.4**	0.009
FAST-LIO2 [21]	6.8	0.030
Wildcat [30]	2.9	0.010
DLIOM	**2.4**	**0.007**

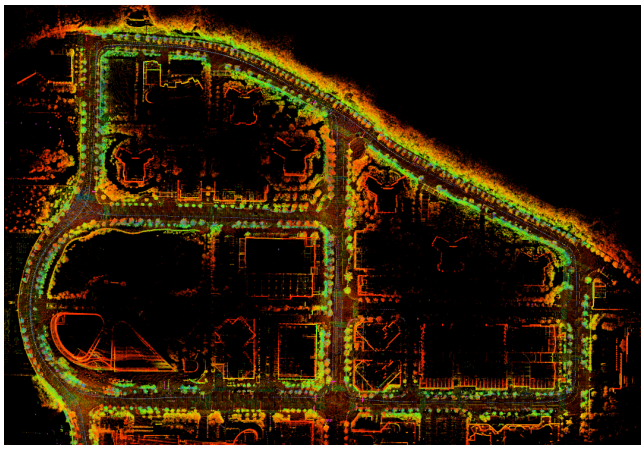


图 14. **MulRan DCC03**。 DLIOM 生成的 MulRan DCC03 数据集地图俯视图。该特定数据集记录了在韩国绕行三个不同环线、约 5421.82 米的行驶路程。

其中，关键帧（白色节点）被放置在场景变化较大的位置（例如穿过门口、楼梯之间）。

3) MulRan 数据集：为了与 Wildcat 进行比较， [30]，我们使用 MulRan DCC03 [48] 数据集。结果如表 IV 所示（LIO-SAM、FAST-LIO2 和 Wildcat 的结果取自 [30]）。虽然具体如何计算相对轨迹误差（RPE）的细节尚不清楚，但我们假设平移指标是使用 evo [51],根据点距离误差比计算的平均 RPE，而旋转指标则使用 evo 的“rot part”选项。无法对绝对轨迹误差进行公平比较 –

<escape>由于作者未提供数值，因此未进行数值比较，但 DLIOM 的 ATE 平均值为 2.36m 和 2.4°。俯视地图如图 14。</escape>

4) 加州大学洛杉矶分校校园数据集： 此外，我们使用加州大学洛杉矶分校的四个大型数据集展示了我们方法的准确性，以进行进一步比较（图 15）。这些数据集通过手持我们的航空平台（图 1）在总计 2261.37 米的轨迹范围内采集。我们的传感器套件包括一个 Ouster OS1（10Hz、32 个通道，水平分辨率为 512）以及一个安装在其下方约 0.1 米处的 6 轴 InvenSense MPU-6050 惯性测量单元。需要指出的是，这款惯性测量单元的售价约为 10 美元，这表明激光惯性里程计算法并不一定需要以往研究所使用的高端惯性测量单元。由于缺少真实值，无法比较绝对轨迹误差，因此按照惯例，我们计算端到端平移误差，作为替代指标（表V）。在这些实验中，我们的方法在端到端平移误差方面全面优于其他所有方法。然而，与 Newer College 数据集中的趋势类似，由于自 DLIO 以来新增了算法组件，我们的平均每次扫描计算时间略有增加。尽管如此，我们生成的地图仍能捕捉环境中的精细细节，最终为地形可通行性等自主移动机器人应用提供更丰富的信息线索。

VIII. 讨论

本文介绍了直接激光雷达-惯性里程计与建图（DLIOM），这是一种稳健的 SLAM 算法，极度注重运行可靠性和精度，可在各种领域中实时生成状态估计和环境地图。DLIOM 通过架构重组和多项算法创新，缓解了典型基于激光雷达的 SLAM 方案中常见的若干故障点。与其他算法通常采用单一传感器融合框架（例如概率滤波器或图优化）同时实现定位和建图不同，我们将这两个过程拆分到独立线程中并分别处理。借助非线性几何观测器，可确保惯性测量单元传播结果收敛至激光雷达扫描匹配结果，并可靠地初始化速度和传感器偏置，

表 V 加州大学洛杉矶分校校园数据集对比

算法	Type	罗伊斯礼堂 (A) *652.66m*		科学广场 (B) *526.58m*		布鲁因广场 (C) *551.38m*		雕塑花园 (D) *530.75m*	
		误差 [m]	计算时间 [ms]	误差 [m]	计算时间 [ms]	误差 [m]	计算时间 [ms]	误差 [m]	计算时间 [ms]
DLO [20]	LO	0.0216	20.40	1.2932	20.77	0.0375	21.18	0.0178	21.62
CT-ICP [46]	LO	0.0387	351.85	0.0699	342.76	0.0966	334.15	0.0253	370.19
KISS-ICP [50]	LO	0.0689	50.28	0.4007	31.84	0.2412	35.31	0.0987	62.96
LIO-SAM [13]	LIO	0.0216	33.21	0.0692	29.14	0.0936	39.04	0.0249	48.94
FAST-LIO2 [21]	LIO	0.0454	15.39	0.0353	12.25	0.0363	14.84	0.0229	15.01
DLIO [6]	LIO	0.0105	**10.45**	0.0233	**8.37**	0.0301	**8.66**	0.0082	**10.96**
DLIOM	LIO	**0.0097**	12.91	**0.0228**	14.18	**0.0235**	15.37	**0.0078**	13.78

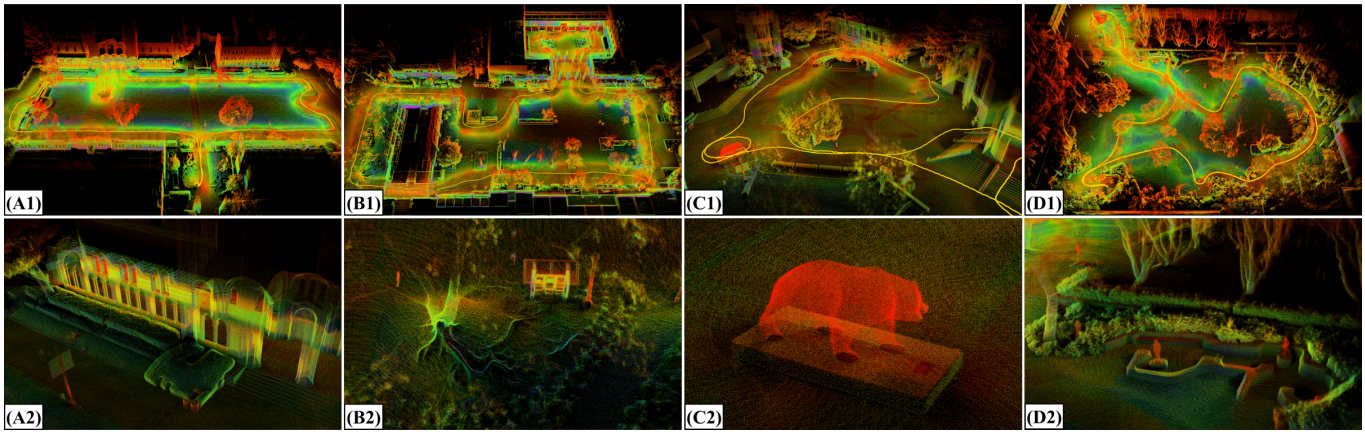


图15. **加州大学洛杉矶分校校园**。由我们的算法生成的美国加利福尼亚州洛杉矶市加州大学洛杉矶分校周边位置的详细地图，包括 (A) 迪克森庭院内的罗伊斯礼堂、(B) 科学广场、(C) 布鲁因广场，以及 (D) 富兰克林·D·墨菲雕塑花园。每个地点均展示了 (1) 鸟瞰图和 (2) 特写图，以体现 DLIO 所能生成的精细程度。用于生成这些地图的轨迹以黄色显示在第一行中。

这是我们快速由粗到精运动校正技术所必需的。另一方面，因子图以里程计线程确定的关键帧位置为节点，通过重叠关键帧之间的连接因子持续优化，以获得最佳拟合地图；这些连接因子为优化问题提供了额外的相对约束。

通过前端的扫描匹配、关键帧选择和子地图构建过程，以分层方式实现快速且鲁棒的定位。自适应扫描匹配方法通过计算一种新颖的点云稀疏度指标，自动调整广义迭代最近点（GICP）中对应平面之间的最大距离，从而在不同规模的环境中实现更加一致的配准。抗滑移关键帧选取通过采用一种新型的与传感器无关的退化度量来检测突发的场景变化，确保扫描与子地图之间具有足够数量的数据对应关系。最后，我们通过计算当前扫描与每个环境关键帧之间的三维杰卡德指数，显式生成子地图，以确保子地图在数据对应关系搜索过程中具有最大的重叠度。这些方法共同实现了一种高度可靠的激光雷达同步定位与地图构建系统，该系统不仅不受运行环境的限制，而且速度快、能够在线运行，可在计算资源受限的平台上实现实时应用。

参考文献

[1] C. Cadena、L. Carlone、H. Carrillo、Y. Latif、D. Scaramuzza、J. Neira、I. Reid 和 J. J. Leonard，“同步定位与建图的过去、现在与未来：迈向鲁棒感知时代”，*IEEE*机器人学汇刊，第32卷，第6期，第1309–1332页，2016年。[2] A. Tagliabue、J. Tordesillas、X. Cai、A. Santamaria-Navarro、J. P. How、L. Carlone 和 A.-a. Agha-mohammadi，“LION：面向无视觉环境的激光雷达惯性可观测性感知导航器”，载于国际实验机器人研讨会，2020年，第380–390页。[3] K. Koide、M. Yokozuka、S. Oishi 和 A. Banno，“黑箱激光雷达里程计的自适应超参数调优”，载于*2021*年*IEEE/RSJ*智能机器人与系统国际会议（*IROS*），2021年，第7708–7714页。[4] ——，“黑箱激光雷达里程计的自动超参数调优”，载于*2021*年*IEEE*国际机器人与自动化会议（*ICRA*），2021年，第5069–5074页。[5] T. Tuna、J. Nubert、Y. Nava、S. Khattak 和 M. Hutter，“X-ICP：面向极端环境中鲁棒定位的可定位性感知激光雷达配准”，*arXiv*预印本 *arXiv:2211.16335*，2022年。[6] K. Chen、R. Nemiroff 和 B. T. Lopez，“直接激光雷达-惯性里程计：采用连续时间运动校正的轻量级激光惯性里程计”，*IEEE*国际机器人与自动化会议（*ICRA*），2023年。[7] P. J. Besl 和 N. D. McKay，“三维形状的配准方法”，载于传感器融合*IV*：控制范式与数据结构，第1611卷，1992年，第586–606页。[8] Y. Chen 和 G. Medioni，“通过多幅距离图像配准进行物体建模”，《图像与视觉计算》，第10卷，第3期，1992年，第145页。[9] A. Segal、D. Haehnel 和 S. Thrun，“广义迭代最近点”，载于《机器人学：科学与系统》，第2卷，第4期，2009年，第435页。

[10] P. Biber 和 W. Strasser，“正态分布变换：一种新的激光扫描匹配方法”，载于《2003年 IEEE/RSJ智能机器人与系统国际会议论文集》（IROS 2003）（目录号03CH37453），第3卷，2003年，第2743–2748卷，第3页。[11] J. Zhang 和 S. Singh，“Loam：实时激光雷达里程计与建图”，载于《机器人学：科学与系统》，第2卷，第9期，2014年，第1–9页。[12] T. Shan 和 B. Englot，“Lego-loam：可变地形上的轻量级且地面优化激光雷达里程计与建图”，载于《IEEE/RSJ智能机器人与系统国际会议》，2018年，第4758–4765页。[13] T. Shan、B. Englot、D. Meyers、W. Wang、C. Ratti 和 D. Rus，“Lio-sam：通过平滑与建图实现紧耦合激光雷达-惯性里程计”，载于《IEEE/RSJ智能机器人与系统国际会议》，2020年，第5135–5142页。[14] T. Shan、B. Englot、C. Ratti 和 D. Rus，“Lvi-sam：通过平滑与建图实现紧耦合激光雷达-视觉-惯性里程计”，载于《IEEE国际机器人与自动化会议》，2021年，第5692–5698页。[15] Y. Pan、P. Xiao、Y. He、Z. Shao 和 Z. Li，“Mulls：通过多度量线性最小二乘实现通用激光雷达同步定位与建图”，载于《IEEE国际机器人与自动化会议》，2021年，第11 633–11 640页。[16] W. Xu 和 F. Zhang，“Fast-lio：通过紧耦合迭代卡尔曼滤波器实现的快速、鲁棒激光雷达-惯性里程计软件包”，《IEEE机器人与自动化快报》，第6卷，第2期，第3317–3324页，2021年。[17] T.-M. Nguyen、S. Yuan、M. Cao、L. Yang、T. H. Nguyen 和 L. Xie，“Miliom：紧耦合多输入激光雷达-惯性里程计与建图”，《IEEE机器人与自动化快报》，第6卷，第3期，第5573–5580页，2021年。[18] H. Ye、Y. Chen 和 M. Liu，“紧耦合三维激光雷达惯性里程计与建图”，载于《国际机器人与自动化会议》，2019年，第3144–3150页。[19] M. Palieri、B. Morrell、A. Thakur、K. Ebadi、J. Nash、A. Chatterjee、C. Kanellakis、L. Carlone、C. Guaragnella 和 A.-a. Agha-Mohammadi，“Locus：用于实时高精度里程计与三维建图的多传感器激光雷达中心化方案”，《IEEE机器人与自动化快报》，第6卷，第2期，2020年。[20] K. Chen、B. T. Lopez、A.-a. Agha-mohammadi 和 A. Mehta，“直接激光雷达里程计：使用稠密点云实现快速定位”，《IEEE机器人与自动化快报》，第7卷，第2期，第2000–2007页，2022年。[21] W. Xu、Y. Cai、D. He、J. Lin 和 F. Zhang，“Fast-lio2：快速直接激光雷达-惯性里程计”，《IEEE机器人学汇刊》2022年。[22] A. Reinke、M. Palieri、B. Morrell、Y. Chang、K. Ebadi、L. Carlone 和 A.-A. Agha-Mohammadi，“Locus 2.0：用于实时三维建图的鲁棒且计算高效的激光雷达里程计”，《IEEE机器人与自动化快报》，第1–8页，2022年。[23] Z. Wang、L. Zhang、Y. Shen 和 Y. Zhou，“D-liom：紧耦合直接激光雷达-惯性里程计与建图”，《IEEE多媒体汇刊》，第1–1页，2022年。[24] J. Zhang、M. Kaess 和 S. Singh，“基于优化的状态估计问题的退化性”，载于《2016年 IEEE国际机器人与自动化会议》（ICRA），2016年，第809–816页。[25] G. Baldwin、R. Mahony、J. Trumpf、T. Hamel 和 T. Cheviron，“特殊欧氏群 SE（3）上的互补滤波器设计”，载于《2007年欧洲控制会议》（ECC）。IEEE，2007年。[26] J. F. Vasconcelos、C. Silvestre 和 P. Oliveira，“用于刚体姿态与位置估计的非线性 GPS/IMU 观测器”，载于《2008年 IEEE决策与控制会议》。IEEE，第1255–1260页。[27] T. Renzler、M. Stolz、M. Schratter 和 D. Watzenig，“提高快速运动激光雷达的精度：畸变点云校正”，载于《IEEE国际仪器与测量技术会议》，2020年。[28] S.-P. Deschˆenes、D. Baril、V. Kubelka、P. Giguere 和 F. Pomerleau，“对极端运动具有鲁棒性的激光雷达扫描配准”，载于《机器人与视觉会议》，2021年。[29] C. Park、P. Moghadam、S. Kim、A. Elfes、C. Fookes 和 S. Sridharan，“Elastic LiDAR Fusion：稠密地图中心化连续时间SLAM”，载于《2018年 IEEE国际机器人与自动化会议》（ICRA），2018年，第1206–1213页。[30] M. Ramezani、K. Khosoussi、G. Catt、P. Moghadam、J. Williams、P. Borges、F. Pauling 和 N. Kottege，“Wildcat：在线连续时间三维激光雷达-惯性SLAM”，arXiv预印本 arXiv:2205.12595，2022年。[31] D. Droeschel 和 S. Behnke，“用于基于三维激光雷达的在线建图的高效连续时间SLAM”，载于《2018年 IEEE国际机器人与自动化会议》（ICRA），2018，第 5000–5007 页。

[32] P. Dellenbach、J.-E. Deschaud、B. Jacquet 和 F. Goulette，“CT-ICP：具有回环闭合功能的实时弹性激光雷达里程计”，载于 2022年国际机器人与自动化会议（ICRA）。IEEE，2022年，第 5580–5586 页。[33] C. Park、P. Moghadam、J. L. Williams、S. Kim、S. Sridharan 和 C. Fookes，“弹性与连续时间相结合：以地图为中心的稠密三维激光雷达同步定位与建图”，IEEE机器人学汇刊，第 38 卷，第 2 期，第 978–997 页，2022年。[34] Z. Liu 和 F. Zhang，“Balm：用于激光雷达建图的捆绑调整”，IEEE机器人与自动化快报，第 6 卷，第 2 期，第 3184–3191 页，2021年。[35] I. Vizzo、T. Guadagnino、B. Mersch、L. Wiesmann、J. Behley 和 C. Stachniss，“KISS-ICP：为点到点ICP正名——方法得当时，配准简单、准确且稳健”，IEEE机器人与自动化快报（RA-L），第 8 卷，第 2 期，第 1029–1036 页，2023年。[36] K. Ebadi、M. Palieri、S. Wood、C. Padgett 和 A.-a. Aghamohammadi，“DARE-SLAM：感知退化环境中具备退化感知能力且稳健的回环闭合”，智能与机器人系统期刊，第 102 卷，第 1–25 页，2021年。[37] Fuzhang Han、Han Zheng、Wenjun Huang、Rong Xiong、Yue Wang 和 Yanmei Jiao，“DAMS-LIO：具有退化感知能力的模块化传感器融合激光雷达惯性里程计”，2023年。 [在线]。获取地址：https://arxiv.org/abs/2302 01703 。[38] H. Lim、D. Kim、B. Kim 和 H. Myung，“AdaLIO：退化室内环境中的稳健自适应激光雷达惯性里程计”，2023年。[39] G. Kim 和 A. Kim，“Scan Context：用于三维点云地图中地点识别的自我中心空间描述符”，载于 IEEE/RSJ智能机器人与系统国际会议论文集，马德里，2018年10月。[40] G. Kim、S. Choi 和 A. Kim，“Scan Context++：在城市环境中对旋转和横向变化具有鲁棒性的结构化地点识别”，IEEE机器人学汇刊，2021年，已录用，即将发表。[41] P. Yin、S. Yuan、H. Cao、X. Ji、S. Zhang 和 L. Xie，“Segregator：结合语义与几何线索的全局点云配准”，arXiv预印本 arXiv:2301.07425，2023年。[42] B. T. Lopez，“用于位姿惯性融合的收缩分层观测器”，arXiv:2303.02777，2023年。[43] L. Zhang、M. Camurri 和 M. Fallon，“对 Newer College 数据集的多相机激光雷达惯性扩展”，2021年。[44] P. Jaccard，“高山带植物区系的分布”，New Phytologist，第 11 卷，第 2 期，第 37–50 页，1912年。[在线]。获取地址：https://nph.onlinelibrary.wiley.com/doi/abs/10.1111/j.1469-8137.1912.tb05611.x [45] R. Nemiroff、K. Chen 和 B. T. Lopez，“流形上的重力与加速度计内参联合估计”，2023年。 [在线]。获取地址：https://arxiv.org/abs/2303 03505 。[46] P. Dellenbach、J.-E. Deschaud、B. Jacquet 和 F. Goulette，“CT-ICP：具有回环闭合功能的实时弹性激光雷达里程计”，2021年。[47] M. Ramezani、Y. Wang、M. Camurri、D. Wisth、M. Mattamala 和 M. Fallon，“Newer College 数据集：配备真实值的手持式激光雷达、惯性与视觉数据”，载于 2020年 IEEE/RSJ智能机器人与系统国际会议（IROS），2020年，第 4353–4360 页。[48] G. Kim、Y. S. Park、Y. Cho、J. Jeong 和 A. Kim，“MulRan：用于城市地点识别的多模态测距数据集”，载于 IEEE国际机器人与自动化会议（ICRA）论文集，巴黎，2020年5月。[49] D. Girardeau-Montaut、M. Roux、R. Marc 和 G. Thibault，“使用地面激光扫描仪采集的点云数据进行变化检测”，ISPRS，2005年。[50] I. Vizzo、T. Guadagnino、B. Mersch、L. Wiesmann、J. Behley 和 C. Stachniss，“KISS-ICP：为点到点ICP正名——方法得当时，配准简单、准确且稳健”，IEEE机器人与自动化快报（RA-L），第 8 卷，第 2 期，第 1–8 页，2023年。[51] M. Grupp，“evo：用于评估里程计与同步定位和建图的 Python 软件包。”https://github.com/MichaelGrupp/evo，2017年。[52] J. Sturm、N. Engelhard、F. Endres、W. Burgard 和 D. Cremers，“用于评估 RGB-D SLAM 系统的基准”，载于智能机器人系统国际会议（IROS）论文集，2012年10月。[53] S. Umeyama，“两个点模式之间变换参数的最小二乘估计”，IEEE模式分析与机器智能汇刊，第 13 卷，第 4 期，第 376–380 页，1991年。