

DOI: 10.19650/j.cnki.cjsi.J2615278

一种稳健的级联式点云运动状态判断方法^{*}

高佳鑫, 隋 心, 王长强, 徐爱功

(辽宁工程技术大学测绘与地理科学学院 阜新 123000)

摘 要: 动态目标直接影响基于激光雷达的同时定位与建图 (LiDAR SLAM) 的定位精度和建图质量, 进而对自主导航、空间规划等实际应用构成安全隐患。然而, 现有研究存在依赖启发式阈值、需要丰富特征、模型结构复杂以及实时性欠佳等局限, 因此提出一种稳健的级联式点云运动状态判断方法。首先, 构建包含 6 帧点云的滑动窗口, 基于其中各帧点云聚类结果, 采用一种质心双重配准策略建立同目标点云簇的连续配对关系, 以此分别构建 5 个单位长度的相对位置变化向量和点云密度变化向量。其次, 针对上述两种特征描述向量, 采用局部离群因子 (LOF) 将前者在零向量处聚集的点云簇标记为稳定静态, 在剩余点云簇中将后者在零向量处聚集的对象标记为稳定动态。最后, 通过适应优化核密度估计 (KDE) 算法获取点云簇内部坐标峰值分布, 并在窗口内评估峰值稳定性以识别遮挡或视场变化导致的不稳定静态或动态点云簇。此外, 每次更新窗口后, 已被标记为动态的点云簇保持状态追踪, 不再执行上述流程以大幅缩减处理耗时。实验表明, 本研究相应的动态点云簇正确检测率达到 0.928 2, 静态点云簇错误检测率仅为 0.043 6, 单帧点云处理耗时为 28.15 ms; 在实测场景中, 性能优于对比方法, 并展现出更强的稳健性和适用性。

关键词: 点云运动状态判断; 级联方法; LiDAR SLAM; LOF; KDE

中图分类号: TP391.4 TH7 **文献标识码:** A **国家标准学科分类代码:** 420·10

A robust cascaded method for point cloud motion state determination

Gao Jiaxin, Sui Xin, Wang Changqiang, Xu Aigong

(College of Geomatics, Liaoning Technical University, Fuxin 123000, China)

Abstract: Dynamic targets directly affect the localization accuracy and mapping quality of light detection and ranging-based simultaneous localization and mapping (LiDAR SLAM), thereby posing potential safety risks to practical applications such as autonomous navigation and spatial planning. However, existing studies generally have limitations such as reliance on heuristic thresholds, requirement for abundant features, complex model structures, and inadequate real-time performance. Therefore, this paper proposes a robust cascaded method for point cloud motion state determination. First, a sliding window containing six frames of point cloud data is constructed. Based on the clustering results of each frame within the window, a dual centroid registration strategy is adopted to establish continuous matching relationships for point cloud clusters belonging to the same target. On this basis, five unit-length relative position change vectors and point cloud density change vectors are constructed respectively. Second, the local outlier factor (LOF) is used to mark as stable static those point cloud clusters whose relative position change vectors cluster near the zero vector. Among the remaining clusters, those whose point cloud density change vectors cluster near the zero vector are marked as stable dynamic. Finally, this study adaptively optimizes the kernel density estimation (KDE) algorithm to acquire the peak distribution of coordinates inside point cloud clusters, and evaluates peak stability within the window to distinguish unstable static or dynamic point cloud clusters caused by occlusion or field of view changes. Furthermore, after each window update, the point cloud clusters already marked as dynamic are no longer subjected to the aforementioned motion state judgment process, thereby greatly reducing the processing time. Experiments show that the correct detection rate of dynamic point clouds in this study reaches 0.928 2, the false detection rate of static point clouds is only 0.043 6, and the single-

收稿日期: 2026-05-14 Received Date: 2026-05-14

^{*} 基金项目: 国家自然科学基金项目 (42404045)、辽宁省自然科学基金计划博士科研启动项目 (2024-BS-256)、辽宁省教育厅基本科研项目 (LJ212410147093)、辽宁省教育厅基本科研项目 (LJ212510147025) 资助

frame point cloud processing time is 28.15 ms. In actual measurement scenes, its performance is generally superior to that of comparative methods, and it exhibits stronger robustness and applicability.

Keywords: point cloud motion state determination; cascaded method; LiDAR SLAM; LOF; KDE

0 引 言

近年来,在智能感知与自主移动需求的迫切驱使下,基于激光雷达(light detection and ranging, LiDAR)、相机、惯性测量单元(inertial measurement unit, IMU)以及其他传感器的同时定位与建图(simultaneous localization and mapping, SLAM)技术蓬勃发展,已成为自主导航、空间规划、智能巡检等领域的核心支撑^[1-2]。其中, LiDAR SLAM 凭借量测精度高、受光照影响小、建图直观等优势,更广泛地应用于无人驾驶、机器人作业、工程管理等众多实际场景^[3]。但是,作为该项技术的首要核心环节,点云帧间配准依赖扫描环境完全静态的条件才能输出准确的帧间相对位姿变化,故运动目标生成的动态点云会引入显著的定位误差。同时,还会在点云地图中残留大量噪声,严重影响地图的完整性和可靠性,进而对路径规划、障碍物规避、环境感知等应用构成隐患^[4-5]。因此,如何高效、精准地判断点云运动状态,进而剔除动态点云并保留静态有效信息,始终是提升 LiDAR SLAM 性能的关键,也是当前相关领域的研究热点。

针对上述问题,根据数据基础不同, LiDAR 点云运动状态判断相关研究主要分为基于预构地图方法和基于实时点云方法。其中,前者将预构静态地图作为基准,通过对比单帧点云与地图差异移除动态点云;后者通过挖掘点云间时空特征判断运动状态,更适合在未知场景中实时执行动态点云剔除任务。

根据数据结构不同,基于预构地图方法还可细分为基于体素方法和基于距离图像方法。基于体素方法针对单帧点云和地图构建体素集,结合激光沿直线传播且击中目标终止的性质,筛选并释放动态体素以消除动态建图噪声。其中, Schauer 等^[6]针对每束激光均标记路径上的体素状态,当后续某些体素由空闲转为占用时则对应判定为动态点云,其体素遍历复杂度取决于场景规模,且处理高密度点云的实时性不足; Lim 等^[7]则将空间按方位角和径向距离划分为若干体素,分别计算点云高度差作为伪占有率,以此对比点云与地图伪占有率差异筛选动态区域;基于上述研究, Zhou 等^[8]计算伪占有率预先筛选潜在动态体素,以降低大规模场景下体素遍历运算量。为进一步降低运算和存储开销,基于距离图像方法将地图和点云投影为图像,通过对比两者间不同观测视角的可见性差异筛选动态点云。其中, Kim 等^[9]构建多分辨率距离图像,并通过测距值一致性检验初步移除动

态点,再基于可见性检验恢复误判静态点; Qian 等^[4]利用 IMU 预积分辅助构建自适应多分辨率图像,同样根据图像差异移除动态点并通过点云配准优化位姿,当配准误差不收敛则调整图像分辨率,并迭代执行动态移除和位姿优化。经相应实验验证,上述基于预构地图方法均能有效检测动态点云,并剔除地图中动态噪声,但始终面临需要预构纯净地图且无法适用未知场景问题,故在实际应用中逐渐被基于实时点云方法取代。

目前,基于实时点云方法可以细分为基于配准残差解析方法、基于耦合式优化方法以及基于深度学习方法。基于配准残差解析方法直接根据点云配准残差并结合运动规律判断点云状态,适用运算资源受限的处理需求。其中, Jia 等^[10]计算点云局部曲率区分边缘与平面特征进行帧间配准,如果配准残差超过阈值且运动方向不符合静态背景规律,则判定为动态点云,其性能受阈值适配性影响,且低速目标漏检频发;在此基础上考虑时序信息, Chen 等^[5]基于 5 帧点云构建连续序列,结合空间和时间维度设计分割式卷积神经网络,输入配准残差的时空变化以输出动态概率。该类方法流程清晰且处理效率较高,但通常忽略了动态点云对配准的影响,导致动态聚集情况下运动状态误判率极高。相比之下,基于耦合式优化方法打破了动态检测与其他环节割裂的模式,通过相互反馈实现双向优化,解决了上述方法状态检测依赖位姿精度,但位姿估计受动态干扰的循环问题。其中, Fan 等^[11]设计了高频前端配准和低频建图耦合系统,前端基于背景减法和多目标跟踪策略,利用局部地图增强动静分离效果,建图则基于前端输出的静态点,结合可见性检查与占用概率计算更新全局地图; Tian 等^[12]进一步深化了耦合逻辑,基于轨迹多项式拟合和距离阈值关联实现帧间目标跟踪,并将载体姿态、静态目标位置、动态目标轨迹均纳入窗口进行协同优化,实现动态检测效果和定位精度的同步提升。虽然该类方法使动态检测与位姿估计、建图形成互促闭环,但协同优化带来的高额负载易影响实时性,且单一环节误差易引发整体系统失衡。相较于上述两类方法,基于深度学习方法不需要预设复杂前提条件,通过挖掘点云的时空特征并输入网络模型即可自动执行运动状态判断。其中, Zhao 等^[13]将点云投影至二维网格以构建统计特征输入全卷积网络,根据输出的网格属性初步判断目标状态,并采用压缩并查集算法确定动态点云;为进一步丰富输入特征, Vaquero 等^[14]将点云投影为前视图和鸟瞰图,并设计双分支卷积神经网络(convolutional neural network, CNN)协同识别动态目

标,其中前视图网络采用反卷积架构,鸟瞰图网络则引入 fire 模块以减少网络参数;Chen 等^[15]则采用 RangeNet++ 网络处理点云球面投影并输出各点语义标签,通过腐蚀和深度填充优化语义分割,以此构建包含语义标签和稳定性权重的地图,并基于点云与地图语义一致性检测和稳定性权重更新判别动态点;为降低人为干预并提高推理连贯性,Li 等^[16]设计端到端全卷积网络直接预测动态目标置信度和边界框,但仅能识别动态车辆,模型泛化能力有限且标注成本较高;Pfreundschuh 等^[17]提出基于占用栅格的自动标注流程,通过遍历多帧点云的空间占用变化自动标注动态目标,但标注质量依赖位姿估计精度,漂移严重时易产生错误标签。虽然上述基于深度学习方法受人为主观因素影响较小,但对硬件算力普遍要求较高,且通常伴随繁杂的标注和训练工作。

综上所述,现有方法普遍存在不同程度的应用局限。其中,基于预构地图方法受限于静态地图的强依赖,无法适配未知场景;基于配准残差解析方法受阈值制约,且存在配准误差与检测偏差之间的恶性循环;基于耦合式优化方法存在运算负载过高问题,系统整体稳健性不足;基于深度学习方法面临算力需求苛刻、训练成本高以及模型泛化能力有限等实际应用挑战。为避免上述问题,本文提出一种稳健的级联式点云运动状态判断方法,属于基于实时点云方法范畴,摆脱了对预构地图的依赖。该方法构建 6 帧容量滑动窗口,采用点云簇质心双重配准策略规避动态点云干扰,从而建立精确的帧间点云簇配对关系;基于窗口中点云簇连续配对关系,从最基础的运动趋势和形态外观角度提取时序特征,以此用于点云簇运动状态判断,与其他基于多帧统计特征判断运动状态方法相似,所提取特征在受目标间遮挡或扫描视场变化影响时,其数值表征与实际运动状态可能不符,但由于本文仅基于此判断稳定点云簇运动状态且条件严格,故出现误检概率较低;基于上述点云簇配对关系和时序特征,采用局部离群因子(local outlier factor, LOF)与核密度估计(kernel density estimation, KDE)算法构建了无监督的级联式架构,显著削弱了经验参数和人工阈值的干扰,但区别于其他无监督方法使用的扁平式一步判断逻辑,本文架构根据严格条件处理时序特征来标记稳定静态或动态点云簇,并通过追踪局部坐标稳定峰值在剩余点云簇中判断被漏检的稳定点云簇,以及由遮挡或视场变化导致的不稳定点云簇的运动状态;上述处理逻辑有效避免了点云簇状态被误判,结合精确的帧间点云簇配对结果,故相较于其他方法更适配动态追踪机制,在保证检测精度的同时大幅缩减了每帧需要处理的点云簇数量。此外,构建的相对位置变化向量和点云密度变化向量分别与稳定静态点云簇和动态点云簇的基本判断属性相匹配,两类特征各有侧重,从根

本上规避了并行判断模式中多特征同步决策引发的冗余或矛盾;整体处理流程遵循先标记稳定静态,再从剩余点云簇中筛选稳定动态,最后处理遮挡或视场变化导致的不稳定簇的逻辑,全程没有重复运算。同时,级联式处理流程有效避免了上述耦合式系统因高运算负载引发的响应延迟或整体失衡风险,且不需要标注数据集进行模型训练,也不依赖高性能硬件支持,使其具备更广泛的适用性。

1 研究框架

本文提出的级联式点云运动状态判断方法的整体架构如图 1 所示。

本文方法各部分层层递进,形成清晰稳健的级联式处理流程,主要工作及贡献包括:

1) 运动状态判断特征构建:针对引言部分所述现有研究缺乏特征针对性和时序连贯性问题,通过动态递推维护 6 帧点云容量的滑动窗口,并采用质心双重配准策略建立相同目标点云簇的连续配对关系,以此构建 5 个单位长度的相对位置变化向量和点云密度变化向量,并作为运动状态判断特征。上述向量精准刻画了相应点云簇运动趋势和形态外观的最基本变化规律,相较于常用的帧间配准残差特征更具宏观性,且结合相应配对方式有效避免了动态点云干扰特征构建质量。同时,相较于包围盒体积变化,点云密度变化更能削弱目标间遮挡对特征真实性的影响。

2) 级联式点云运动状态判断:为降低算法复杂度并保证运动状态判断的精准性,本文设计了清晰的级联式点云运动状态判断架构,通过稳健的分层递进筛选和动态追踪机制实现精准高效地处理。首先,输入当前帧所有点云簇的相对位置变化向量和零向量,采用 LOF 执行离群检测,将相对位置变化向量与零向量在特征空间同属一个高密度区域的点云簇直接标记为稳定静态。其次,针对未标记点云簇,同样采用 LOF 将点云密度变化向量在零向量处形成局部聚集的点云簇标记为稳定动态。最后,剩余未标记点云簇普遍为目标间遮挡或扫描视场变化导致的不稳定簇,对此采用 KDE 获取各点云簇 X、Y 轴坐标的峰值分布,并根据窗口内配对点云簇的峰值变化规律区分运动状态;其中,为降低局部噪声对整体峰值分布的干扰,采用带噪声的基于密度的空间聚类(density-based spatial clustering of applications with noise, DBSCAN)算法对坐标数据进行无监督划分,并对各区段独立执行峰值估计,以提升峰值分析准确性。此外,已被标记为动态的点云簇在窗口更新过程中始终保持状态追踪,以此大幅降低需要判断运动状态的点云簇数量,进一步提升处理效率。




图1 级联式点云运动状态判断方法的整体流程架构

Fig. 1 Overall framework of cascaded method for point cloud motion state determination

2 研究方法

2.1 点云初步处理

由于LiDAR内部结构精密,在长时间未校准或颠簸影响下极易产生设备系统误差。同时,原始点云普遍存在运动畸变、噪声分散、过度稠密等问题。因此,在以点

云为数据基础的的实际应用中,为获取高质量结果,必须预先开展内参补偿和必要预处理工作。

首先,采用无监督点云优化方案^[18]标定内参,并以此补偿系统误差。为避免引入额外传感器数据,基于滤除动态目标的点云构建LiDAR里程计,并借鉴速度更新迭代最近点算法的基本原理消除点云运动畸变^[19]。经上述处理,点云质量显著提升,但由于本文研究对象为独

立点云簇,故离散噪声点不具有研究价值,为此构建覆盖整体点云的体素网络并筛选稀疏体素,将被筛选体素中的点云视为离散噪声并剔除^[20]。此外,利用各体素的点云质心代替整个体素,以此降低点云密度。

其次,针对经内参补偿和预处理后的点云,采用地面分割及点云簇聚类算法获取独立点云簇聚类结果^[21]。该算法基于二维连通组件标记和三维体素差异性分析构建双重分割体系,适用于处理不同分辨率点云,并具备优异的跨场景适配性。尽管实际中个别贴合目标由于未满足细分条件被聚为一类,但此类目标间运动状态通常趋于一致并具备空间稳定性,且数量占比较低,故对整体点云运动状态判断影响较小。

在实验验证中本文采用 RS-LiDAR-32 采集点云,经实际数据处理测试,通过点云分区并结合多线程并行运算,上述内参补偿、畸变去除、体素去噪、体素采样、聚类分割一系列流程相应时间复杂度为 $O((N \log N)/T)$, 空间复杂度为 $O(N)$, T 表示实际并行线程数, N 表示当前帧点云包含的激光点数量。

2.2 状态判断特征构建

为降低点云运动状态判断过程中的偶然性干扰,本文从时间维度构建包含 6 帧连续点云的滑动窗口,并针对其中邻帧点云采用以往研究中提出的质心双重配准策略^[22]构建点云簇配对关系。上述配准策略基于迭代最近点粗匹配和随机采样一致精匹配,统一邻帧点云簇质心的空间基准,有效规避了传统配准策略中动态点运动偏移误差与整体配准误差相混淆问题;在此基础上,该策略设计双向邻近搜索模块划分配对簇和缺失簇,虽然引入了额外计算开销,但大幅提升了点云簇帧间配对完整性,为本文后续构建状态判断特征提供了更稳健的支撑。此外,考虑到上述滑窗容量直接影响点云运动状态检测精度和处理效率,故本文通过调整滑窗大小,并评估对应检测性能以确定最优容量,相应测试结果如表 1 所示。其中,帧数小于 6 帧时,随着窗口容量减少,时序约束严格程度逐渐降低,偶然噪声抑制能力下降,相应动态点云检测效果随之变差,但约束减少使静态点云误检得到缓解,且处理效率逐渐提高;当帧数大于 6 帧后,随着窗口容量增加,动态检测精度提升缓慢,但后续特征向量处理及峰值稳定性估计等环节的计算量和判断条件严格程度均大幅增长,导致静态点云误检情况加剧且单帧处理耗时显著增加。因此,综合考虑两类点云检测效果和处理效率,本文选择 6 帧作为最优滑窗容量。

基于上述窗口中点云簇连续配对结果,为降低特征复杂度并兼顾普遍适用性,从最基本的运动趋势和形态外观角度,设计了相对位置变化和点云密度变化特征,并根据窗口内时序信息分别构建了 5 个单位长度的相对位置变化向量和点云密度变化向量,具体量化方式为:

表 1 不同滑窗容量下本文方法的点云运动状态检测性能
Table 1 Detection performance of point cloud motion state under different sliding window sizes

滑窗包 含帧数	整体动态点云 正确检测率	整体静态点云 错误检测率	单帧点云 处理耗时/ms
3	0.852 5	0.018 7	17.72
4	0.887 3	0.024 0	19.98
5	0.901 7	0.032 2	23.20
6	0.928 2	0.043 6	28.15
7	0.931 9	0.057 3	35.12
8	0.933 5	0.072 8	43.87
9	0.930 1	0.110 5	54.69
10	0.937 4	0.181 3	69.03

1) 以第 i 帧点云中第 k 个点云簇为例,将其质心坐标记为 (X_k^i, Y_k^i, Z_k^i) , 经过邻帧空间基准统一后,计算其与第 $i-1$ 帧点云中配对点云簇 h 的相对位置变化 $l_{k,h}^{i,i-1}$, 如式(1)所示。

$$l_{k,h}^{i,i-1} = \sqrt{(X_k^i - X_h^{i-1})^2 + (Y_k^i - Y_h^{i-1})^2 + (Z_k^i - Z_h^{i-1})^2} \quad (1)$$

基于窗口中其他帧相应配对点云簇的质心,计算帧间相对位置变化,以此构建相对位置变化向量 L_k^i , 如式(2)所示。

$$L_k^i = [l_{u,x}^{i-4,i-5} \quad l_{v,w}^{i-3,i-4} \quad l_{u,v}^{i-2,i-3} \quad l_{h,u}^{i-1,i-2} \quad l_{k,h}^{i,i-1}]^T \quad (2)$$

式中: u, v, w, x 均代表点云簇编号。

同理,按照上述模式构建第 i 帧点云中其他点云簇的相对位置变化向量。

2) 针对点云簇形态外观变化表征方面,最小外包盒体积是最直观简便的方式,但实际上目标间遮挡频发且遮挡程度随机,导致平行外包盒不能准确衡量点云簇形态外观变化,而凹包外包盒虽能贴合目标轮廓,但构建过程繁琐,故该表征方式无法高效且准确地描述点云簇形态外观变化^[23]。针对上述问题,考虑到点云密度能够反映激光点分布聚集程度,其变化既与自身形态改变相关,又能有效捕捉遮挡带来的点云分布波动,且计算过程简洁高效,故通过计算点云密度变化间接表征点云簇的形态外观演变。同样以第 i 帧点云中第 k 个点云簇为例,根据其中各点三轴坐标的最大值和最小值,计算点云簇的三轴跨度 $\Delta X_k^i, \Delta Y_k^i, \Delta Z_k^i$, 并将包含的激光点数量记为 N_k^i , 计算相应的点云密度 H_k^i , 如式(3)所示。

$$H_k^i = N_k^i / (\Delta X_k^i \Delta Y_k^i \Delta Z_k^i) \quad (3)$$

计算其与第 $i-1$ 帧点云中配对点云簇 h 的点云密度变化 $p_{k,h}^{i,i-1}$, 如式(4)所示。

$$p_{k,h}^{i,i-1} = |H_k^i - H_h^{i-1}| / H_h^{i-1} \quad (4)$$

针对窗口中其他帧点云,计算相应配对点云簇间点云密度变化,并构建点云密度变化向量 $\mathbf{P}_k^i$,如式(5)所示。

$$\mathbf{P}_k^i = [p_{w,x}^{i-4,i-5} \quad p_{v,w}^{i-3,i-4} \quad p_{u,v}^{i-2,i-3} \quad p_{h,u}^{i-1,i-2} \quad p_{k,h}^{i,i-1}]^T \quad (5)$$

同理,按照上述模式构建第 i 帧点云中其他点云簇的点云密度变化向量。

上述针对单帧点云构建状态判断特征的时间复杂度为 $O((KM)/T)$,空间复杂度为 $O(KM)$, K 表示当前帧独立点云簇数量, M 表示各点云簇平均包含激光点数量。

2.3 稳定点云簇运动状态判断

基于级联式设计,将第 i 帧点云中各点云簇的相对位置变化向量和点云密度变化向量作为输入,采用 LOF 算法^[24-26]分阶段筛选稳定静态点云簇和稳定动态点云簇。其中,LOF 具备对高维特征空间局部结构的敏感捕捉能力,与本文点云簇状态判断向量处理需求高度契合。一方面,由于稳定点云簇间具有状态一致性,其状态判断向量会在对应特征空间中形成局部聚集簇,而受干扰的不稳定点云簇则表现为离群样本,LOF 通过计算各样本相对其邻域的局部密度差异,可量化表征每个点云簇状态判断向量的离群程度,进而精准区分稳定簇与不稳定簇;另一方面,LOF 不需要严格的数据分布假设,并具备对微弱波动与显著异常的良好区分能力,且计算流程简洁,不会显著增加整体复杂度。具体的稳定点云簇运动状态判断流程为:

静态点云簇在不受外界干扰情况下,其帧间相对位置变化几乎趋近于零。因此,基于第 i 帧点云中各点云簇的相对位置变化向量与零向量构建特征空间,其中稳定静态点云簇相应向量因位置变化微弱,在零向量附近形成高密度局部聚集区域,而其他点云簇相应向量因状态差异呈现离散状态,故采用 LOF 获取在零向量处形成聚集的相对位置变化向量,并将相应点云簇标记为稳定静态。

在第 i 帧剩余未被标记的点云簇中,虽然稳定动态点云簇的相对位置变化存在随机性,但相应的点云密度变化在实际情况下应趋近于零。同理,基于未被标记点云簇的点云密度变化向量与零向量构建特征空间,采用 LOF 获取在零向量处形成聚集的点云密度变化向量,并将相应点云簇标记为稳定动态。

在上述稳定点云簇运动状态判断过程中,由于特征空间内稳定簇特征向量在零向量处呈聚集分布,而不稳定簇特征向量呈更加随机的离散分布,两者间样本密度差异比较显著,故 LOF 核心邻域参数的取值对判断结果影响较小。因此,综合考虑处理效率,本文在合理范围内将其赋值为 5。上述分阶段处理模式避免了位置变化与密度变化两类特征的相互干扰,确保了两步筛选精准聚焦静态以位置稳定为核心、动态以密度稳定

为核心的判断逻辑,时间复杂度为 $O((K \log K)/T)$,空间复杂度为 $O(K)$ 。

2.4 不稳定点云簇运动状态判断

经上述稳定点云簇标记后,剩余点云簇普遍为由目标遮挡、视场变化、瞬时噪声等干扰导致的不稳定点云簇,其帧间相对位置和点云密度变化均具有随机性。由于 LOF 难以针对该类点云的运动状态判断向量形成易区分的局部聚集簇,因此采用 KDE 算法^[27-28]提取并分析点云簇内部 X 、 Y 轴坐标的峰值分布变化规律,以区分当前未标记点云簇中的动态对象和静态对象。鉴于上述两类对象间 Z 轴坐标峰值变化规律不具备区分性,故未同步考虑该维度信息。其中,KDE 适用于捕捉单峰或多峰结构,并以概率密度估计方式精准定位各峰值位置,且对数据噪声有自然平滑能力,能够聚焦探究真实峰值演化规律,为点云簇运动状态判断提供可靠支撑。但是,由于外界干扰通常会破坏点云簇局部坐标分布,而传统 KDE 的全局峰值估计会受到相应干扰,进而影响帧间峰值稳定性分析准确性,故本文采用 DBSCAN^[29-30]对坐标数据预先进行无监督区段划分,并针对各区段单独执行 KDE 峰值估计。此外,由于级联式架构本质上存在误差传递风险,稳定点云簇运动状态判断环节漏检的对象会输入到当前不稳定点云簇处理环节,但由于本文研究目的是区分点云簇运动状态,且两类稳定点云簇判断条件严格,相应的误判概率较低,故即便存在少量漏检稳定点云簇也适配当前的峰值稳定性分析。具体的不稳定点云簇运动状态判断流程为:

针对当前第 i 帧点云中未被标记运动状态的点云簇,以其中第 j 个点云簇为例,基于其包含点云的 X 、 Y 轴坐标分别构建两个坐标值集合 $\mathbf{X}_j^i$ 和 $\mathbf{Y}_j^i$ 。采用 DBSCAN 分别处理上述集合,其中涉及的核心参数 Eps 根据各集合内数据分布计算各点的最邻近距离,并结合肘部拐点法进行自适应赋值^[31-32];min_samples 则根据多组集合数据分布进行统计分析并结合交叉验证择优确定,本文将其赋值为 7。以此为基础,针对每个聚类区段分别采用 KDE 估计坐标峰值,并依次记录峰值位置 fx 和 fy ,以构建峰值描述向量 $\mathbf{FX}_j^i$ 和 $\mathbf{FY}_j^i$,如式(6)所示。

$$\begin{cases} \mathbf{FX}_j^i = [fx_1^j & fx_2^j & \cdots & fx_{n-1}^j & fx_n^j]^T \\ \mathbf{FY}_j^i = [fy_1^j & fy_2^j & \cdots & fy_{m-1}^j & fy_m^j]^T \end{cases} \quad (6)$$

基于窗口中各帧点云空间基准统一结果,采用同样方式构建与上述点云簇相配对点云簇的峰值描述向量。由于该类描述向量的维度通常较低且元素排列具有基本顺序,故直接采用遍历检索模式,解析窗口中连续配对点云簇对应的 6 组峰值描述向量间变化规律。其中,针对 X 、 Y 坐标维度,如果任意维度存在至少一个可连续追踪 5 次的稳定峰,则判定该点云簇为不稳定静态点云簇,否

则标记为不稳定动态。上述判定方式符合“经帧间空间基准统一后,静态点云簇峰值位置在不受干扰时近乎恒定,而动态对象因位置偏移使得峰值无法稳定追踪”的客观规律,以此能够精准区分两类点云簇的本质差异;此外,仅存在一个连续追踪稳定峰即判定为不稳定静态点云簇,其原因在于当点云簇处于静态时,即使受到外界干扰,但其主体绝对位置未发生偏移,且经 DBSCAN 与 KDE 复合处理,赋予了单个峰值充分的代表性和独立性,故单个峰值稳定足以证实点云簇整体的静态属性,不再面临多峰验证存在的冗余和矛盾;同时,双坐标维度独立验证避免了单一维度因局部干扰导致的误判,进一步提升了可靠性。同理,按照上述流程判断第 i 帧点云中其他未被标记点云簇的运动状态,相应时间复杂度为 $O((KM\log M)/T)$,空间复杂度为 $O(KM)$ 。

至此,第 i 帧点云中所有点云簇均被标记了运动状态。在本文方法的实际应用中,针对数据集中首帧和第 2 帧点云,由于仅两帧点云间缺乏时序信息支撑,故相应的点云簇运动状态基于前文质心双重配准策略输出的点云簇配准残差粗略判定;第 3~6 帧点云则按照上述级联式处理流程,仅更改滑窗容量并进行相应处理;经验证滑窗最优容量为 6 帧,故从第 7 帧点云开始,每次递推更新滑动窗口后,已被标记为动态的点云簇保持状态追踪,不再执行上述级联式运动状态判断过程,以大幅缩减处理耗时。

3 实验与分析

3.1 实验数据介绍

目前,面向动态场景 LiDAR SLAM 相关研究使用的数据集多为 SemanticKITTI^[33]、UrbanLoco^[34] 以及自采数据集。由于本文研究主要面向以筛除动态点云进而提高实时定位精度的需求,故认为持续静止的可运动目标同样能够提供稳定特征,并参与里程计构建。因此,虽然 SemanticKITTI 中包含精准的点云语义标签,但该标签难以表述可运动目标处于静止或运动状态,故不能有效验证本文方法的实际性能;UrbanLoco 中未包含语义标签,主要适用于验证动态聚集场景下的定位精度提升效果;相关研究通过自主搭建数据采集平台获取研究数据^[13-14],但相应数据集均未开源。综上,为支撑本文点云运动状态判断的性能测试,实验数据通过自主搭建实验平台在实地采集,原始数据可从通讯邮箱获取。

数据采集平台如图 2(a) 所示,主要由 RS-LiDAR-32、X1 组合导航模块以及 DC1 相机模组组成。LiDAR 和组合导航模块的采集频率均为 10 Hz,相机模组输出视频流数据。其中,利用组合导航定位结果统一邻帧点云坐标基准,以此将质心偏移量大于均值的点云簇标记为潜在动态目标;针对潜在目标,结合视频进行人工复检,

剔除非真实运动导致的误选静态目标,将最终标记结果作为验证点云运动状态判断性能的参考基准。此外,所有数据处理均基于统一硬件配置,CPU 为 Intel Core i7-12700H,14 核 20 线程,基础频率 2.3 GHz;GPU 为 NVIDIA GeForce RTX 3060 Laptop GPU,6 GB GDDR6 显存,CUDA 核心数 3 840;CPU 始终开启性能模式,避免硬件波动干扰结果。

数据采集场景 1 为图 2(b) 所示的公园,属于人流密集的开放场景,主体由行人以及长椅、绿植、器材等静态设施构成;动态行人在空间分布上呈局部密集、整体分散的特征,且运动状态具有较强随机性;静态设施点云轮廓多样且分布零散,行人之间、行人与静态设施间普遍存在遮挡。场景 2 为图 2(c) 所示的夜间城市道路,属于车流密集的开放交通场景,主体由各类机动车、非机动车以及路灯、护栏、交通标识等道路附属设施构成;高速车辆运动趋势有序且帧间位置变化显著,道路设施排列规整且分布连续,车辆之间、车辆与道路设施间存在间歇性遮挡。上述数据采集覆盖了目标种类多样、运动状态多样、遮挡情况多样、光照条件多样等差异化实验条件,能够有效支撑验证本文方法在开放场景下的实际点云运动状态判断性能。各场景对应数据采集轨迹长度依次约为 420、950 m,数据采集时长依次约为 350、520 s,相应原始数据均可从通讯邮箱获取。



图 2 实验平台以及场景

Fig. 2 Experimental platform and scenes

3.2 点云运动状态判断性能测试实验

为验证本文级联式点云运动状态判断方法的实际性能,选取 3 种基于实时点云的动态点云检测方法作为对比,分别属于基于配准残差解析方法(对比 1)^[10]、基于耦合式优化方法(对比 2)^[12] 以及基于深度学习方法(对比 3)^[15]。其中,对比方法涉及的点云预处理流程均与本文一致,而帧间坐标统一方式则采用了各方法的固有设计,依次为广义迭代最近点(generalized iterative closest point, GICP)、轻量化地面优化激光雷达里程计与建图(lightweight and ground-optimized lidar odometry and mapping, LeGO-LOAM)、面元地图构建(surfel mapping, SuMa)对应的里程计算法,如果强行统一将导致实际性能失真,故选择保留各方法的原生设计;此外,针对对比方法 3,由于本文所用 LiDAR 的数据结构以及参考基准中二分类标签与该方法的模型输入完全适配,故在对其

开源代码进行适配实际设备的参数调整后,在自采数据集上完成模型训练。采用 4 种方法分别处理两个实测场景数据,从判断精度和处理效率两方面展开综合对比。其中,基于各场景的参考基准,统计各数据集以及单帧点云中静态和动态目标相应点云数量,同时记录各方法的静态点云误检数和动态点云漏检数。以上述统计结果为基础,通过对应计算比值获取单帧点云的动态点云正确检测率和静态点云错误检测率,并绘制各方法在两个场景中的检测率时间序列图,如图 3、4 所示。此外,进一步计算各方法在各数据集上的整体动态点云正确检测率和静态点云错误检测率,以及单帧检测率方差和基于 Z 分布的 95% 置信区间,并统计数据处理效率,具体量化指标如表 2 所示。其中,“综合”指标以场景 1 和场景 2 中各帧数据的动态点云正确检测率或静态点云错误检测率为样本,并将两场景样本合并为整体集合,进而计算综合均值、方差以及置信区间;“平均”指标则基于场景 1 和场景 2 相应的单帧点云处理耗时,直接计算均值得到。




图 3 场景 1 中 4 种方法的检测效果时间序列图
Fig. 3 Time series plot of detection effects of four methods in scene 1





图 4 场景 2 中 4 种方法的检测效果时间序列图
Fig. 4 Time series plot of detection effects of four methods in scene 2

结合图 3、4 中检测率时序可视化结果以及表 2 中各项量化指标,进行综合分析:

场景 1 中行人运动状态复杂,且包含大量低速目标,同时动态目标聚集和随机遮挡情况普遍存在。在此场景中,对比方法 1 受阈值敏感性影响,低速目标漏检频发,且动态点云和静态遮挡显著干扰帧间配准,图 3 中两种点云检测性能均处于最低水平且波动剧烈;对比方法 2 依托协同优化机制,局部性能显著优于对比方法 1,但目标运动趋势复杂随机,导致轨迹多项式拟合易产生误差,环节间误差传导显著且不断累积,故图中两种点云检测效果均呈现先平缓后波动变差的整体趋势;对比方法 3 的检测效果整体优于前两种方法,但目标杂乱且遮挡普遍,相应语义分割误差增大,导致后续腐蚀和深度填充的补偿程度不稳定,故图中点云检测率随时间存在一定波动。

场景 2 车流量大且行驶速度快,高速目标帧间位置变化显著,多数静态设施点云排列规整,但目标数量和种类更丰富,对各方法的适配性和稳健性提出了额外要求。在此场景中,对比方法 1 检测效果略有提升,高速目标残差易满足判定阈值,但高速点云聚集也干扰了配准精度,同时仍受阈值适配性不足影响,大量低速非机动车、行人及小规模静态地物被误检,故图 4 中其检测性能仍处于最低水平;对比方法 2 得益于多数车辆运动趋势有序,故轨迹拟合与跟踪效果良好,图中动态点云正确检测率随时间变化较平稳,静态点云错误检测率也稳定维持在较低水平;由于场景中目标边界清晰,且仅存在间歇性遮挡,故对比方法 3 的语义分割精度更高,其点云检测性能相对平稳且优于前两种方法。

针对处理效率方面,对比方法 1 凭借清晰流程,相较于其他方法具备快速响应优势;对比方法 2 的协同优化带来高额计算负载,难以适配密集或高速目标聚集的实时处理需求,需要降低数据播发速率避免处理遗漏;虽然对比方法 3 检测效果较好且模型调用速度较快,但硬件

表 2 4 种方法检测性能量化指标

Table 2 Quantitative indicators of detection performance for four methods

指标类型	场景编号	对比方法 1	对比方法 2	对比方法 3	本文方法
整体动态点云 正确检测率	1	0.783 7	0.850 0	0.895 6	0.919 9
	2	0.840 3	0.904 8	0.923 7	0.933 8
	综合	0.817 5	0.882 8	0.912 4	0.928 2
整体动态点云 正确检测率方差	1	0.001 5	0.000 6	0.000 5	0.000 2
	2	0.000 9	0.000 4	0.000 2	0.000 1
	综合	0.001 9	0.001 2	0.000 5	0.000 2
整体动态点云正确 检测率置信区间	1	[0.782 4,0.785 0]	[0.849 2,0.850 8]	[0.894 8,0.896 3]	[0.919 4,0.920 4]
	2	[0.839 4,0.841 1]	[0.904 3,0.905 4]	[0.923 4,0.924 1]	[0.933 5,0.934 1]
	综合	[0.816 6,0.818 4]	[0.882 0,0.883 5]	[0.911 9,0.912 9]	[0.927 9,0.928 5]
整体静态点云 错误检测率	1	0.235 7	0.201 4	0.110 0	0.055 1
	2	0.094 9	0.040 3	0.036 3	0.035 9
	综合	0.151 5	0.105 1	0.066 0	0.043 6
整体静态点云错误 检测率方差	1	0.000 9	0.001 4	0.000 4	0.000 1
	2	0.000 4	0.000 2	0.000 1	0.000 1
	综合	0.005 4	0.007 0	0.001 5	0.000 2
整体静态点云错误 检测率置信区间	1	[0.234 7,0.236 8]	[0.200 1,0.202 7]	[0.109 3,0.110 6]	[0.054 7,0.055 4]
	2	[0.094 4,0.095 5]	[0.039 9,0.040 7]	[0.036 1,0.036 6]	[0.035 7,0.036 2]
	综合	[0.150 0,0.153 1]	[0.103 3,0.106 9]	[0.0651,0.066 8]	[0.043 4,0.043 9]
单帧点云处理 耗时/ms	1	20.03	67.63	36.46	24.23
	2	27.95	59.82	47.89	32.07
	平均	23.99	63.73	42.18	28.15

算力成为核心制约因素,随着目标种类或数量增加,相应计算和存储资源需求随之迅速增大。

本文方法的级联式架构和针对性特征设计有效适配不同场景的差异化需求,其实际表现兼具良好稳健性和高效性。级联式判定先通过 LOF 快速筛选稳定静态或动态目标,再以 DBSCAN 优化的 KDE 峰值分析处理遮挡或视场变化导致的不稳定簇,有效解决了低速动态目标漏检和不稳定静态目标误判问题。此外,场景 2 中间歇性遮挡对判定结果的影响被区段峰值独立分析有效削弱。但是,面对场景 1 中动态目标聚集重叠或持续不稳定遮挡情况,本文峰值分析稳定性略有下降。因此,如图 3、4 所示,本文方法的点云运动状态检测性能均趋于稳定且优于 3 种对比方法,但针对场景 2 的检测性能优于场景 1。同时,动态追踪机制大幅减少需要判定的点云簇数量,有效降低了单帧处理运算量,故处理效率满足嵌入 SLAM 框架的实时需求,仅次于对比方法 1。得益于本文方法上述高效的点云运动状态精准判断能力,相应的动态点云正确检测率达到 0.928 2,静态点云错误检测率仅为 0.043 6,单帧点

云处理耗时 28.15 ms;相较于 3 种对比方法,其动态点云正确检测率依次提高了 13.54%、5.14%、1.73%,静态点云错误检测率依次降低了 71.22%、58.52%、33.94%,单帧点云处理耗时依次变化了 17.34%、-55.83%、-33.25%。此外,本文方法的两类点云检测率方差均仅为 0.000 2,且在各场景以及综合统计中最小,同时相应置信区间最窄,进一步表明其检测性能具备良好的稳健性和跨场景适用性。

3.3 点云运动状态判断稳健性测试实验

基于在两个实验场景中采集的点云,深入验证目标体积、速率、位置三方面因素对本文方法判断精度的影响,同时检验位置变化向量、点云密度变化向量以及局部坐标稳定峰值作为核心判断特征的适用性和稳健性。将 2.2 节针对各点云簇计算的最小外包盒体积作为相应的点云簇体积,基于质心坐标计算点云簇与 LiDAR 的三维空间距离,并基于配点对点云簇质心帧间运动距离计算速率,以此按照表 3 所示规则将所有目标分为 9 类。针对每个类别,分别计算相应的动态点云正确检测率和静态点云错误检测率,如表 4 所示。其中,按速率分类目标中

未包含静态目标,故相应的静态点云错误检测率为空,表中用“-”填充。

表 3 目标分类规则
Table 3 Target classification rules

分类依据	第 1 类	第 2 类	第 3 类
体积/ m^3	(0,2]	(2,15)	[15, + ∞)
速率/ $(\text{m}\cdot\text{s}^{-1})$	(0,5]	(5,10)	[10, + ∞)
位置/m	(0,15]	(15,30)	[30, + ∞)

表 4 不同类别目标的检测效果

Table 4 Detection effects of targets in different categories

具体类别		动态点云正确检测率	静态点云错误检测率
体积	第 1 类	0.930 6	0.041 3
	第 2 类	0.931 5	0.039 2
	第 3 类	0.922 3	0.044 7
速率	第 1 类	0.892 1	—
	第 2 类	0.936 0	—
	第 3 类	0.977 5	—
位置	第 1 类	0.942 7	0.028 6
	第 2 类	0.923 5	0.042 3
	第 3 类	0.910 6	0.065 9

基于表 4 中量化指标,分析目标体积、速率、位置 3 个因素对本文方法性能的影响:在体积方面,大型目标跨度通常比较宽泛,其特征质量受外界干扰概率更高,容易被误判为不稳定目标,但局部峰值稳定性分析机制可有效抵消上述干扰;中小型目标相应特征则更能精准聚焦其运动趋势和形态外观变化,故不同体积目标的检测性能差异较小;相应的动态点云正确检测率变化跨度仅为 0.009 2,静态点云错误检测率变化跨度仅为 0.005 5。在速率方面,中高速目标帧间位移显著,运动特征容易被区分;低速目标虽帧间差异较小,但 LOF 离群检测、DBSCAN 优化的 KDE 局部峰值分析以及动态追踪机制可有效保障其检测效果,故整体呈现中高速最优且低速稳健的效果,相应动态点云检测性能下降 8.736 6%。在位置方面,近距离目标点云分布密集且细节更完整,相应的特征表征更精准可靠;远距离目标受激光传播规律影响,对应点云簇内部绝对点云密度较低,但由于本文构建的点云密度变化向量主要描述点云密度的帧间相对变化,故避免了绝对密度受距离和稀疏扫描的影响;此外,随着目标分布位置变远,相应两类特征描述向量的量化精度下降,导致稳定点云簇漏检概率上升,且目标间相互遮挡情况更加普遍,但得益于本文针

对不稳定点云簇的稳健判断能力和动态追踪机制,抗噪声干扰能力较强,故点云运动状态检测效果始终比较稳定,呈现出随距离增加温和衰减趋势;相应的动态点云正确检测率变化跨度为 0.032 1,静态点云错误检测率变化跨度为 0.037 3。

综上,本文方法面对不同目标特性情况下均展现出比较稳定的性能,尤其在大体积、低速率、远距离、高稀疏等易偏差条件下,凭借核心技术优势能够有效维持高精度和低误判,充分验证了其整体的普适性和稳健性,为点云运动状态精准判断提供了可靠的技术支撑。

3.4 级联式架构有效性测试实验

为验证本文级联式判断架构相较于并行或联合式架构的优势,同时量化评估该架构的误差传递和放大风险,本节设计了两组专项测试实验。首先,通过梳理并行式架构下点云运动状态判断方法的基本流程^[10,22],基于已获取的点云簇运动状态判断特征,设计与本文级联式架构形成对照的并行式判断架构。其中,为避免特征间存在过度尖锐的矛盾,仅选择相对位置变化和局部峰值稳定性作为并行判断特征;同时,设计适配的决策规则以统一判断标准,即点云簇仅在相对位置变化向量不为零且所有坐标局部峰值均未被稳定追踪的情况可被判定为动态,其余情况均判定为静态。以此,从动态点云正确检测率及方差、静态点云错误检测率及方差、处理耗时方面比较两种判断架构之间的实际性能,如表 5 所示。其次,针对本文级联式架构的稳定点云簇标记环节,随机将 5%、10%、20%的稳定点云簇人为抹除标记,使其流入后续不稳定点云簇处理环节,以此模拟稳定点云簇漏检导致的误差传递;由于稳定点云簇判定条件严格,故没有对其误检进行模拟;统计上述 3 种漏检比例下最终的动态点云正确检测率、静态点云错误检测率以及单帧处理耗时,如表 6 所示。

表 5 级联式与并行式架构的点云运动状态判断性能对比

Table 5 Performance comparison of point cloud motion state determination between cascaded and parallel architectures

结构类型	动态点云 正确检 测率	动态点云 正确检测 率方差	静态点云 错误检 测率	静态点云 错误检测 率方差	单帧点云 处理耗 时/ms
级联式架构	0.928 2	0.000 2	0.043 6	0.000 2	28.15
并行式架构	0.892 7	0.000 2	0.037 1	0.000 1	41.68

实验结果表明,受并行式架构的一步式判断影响,相应动态点云筛选条件严格,间接导致静态点云误检情况减少;同时,并行式判断针对所有点云簇均需要处理位置变化和局部峰值稳定性两种特征,面临显著的运算冗余问题;相比之下,级联式架构展现出更优的综合性能,如

表 6 不同漏检比例下级联式架构的点云运动状态判断性能对比

Table 6 Performance comparison of point cloud motion state determination for cascaded architecture under different missing detection ratios

漏检比例/%	动态点云正确检测率	静态点云错误检测率	单帧点云处理耗时/ms
0	0.928 2	0.043 6	28.15
5	0.926 9	0.044 1	28.81
10	0.926 4	0.044 7	29.68
20	0.925 0	0.047 2	31.53

表 5 所示其动态点云正确检测率提升 3.98%,单帧处理耗时降低 32.46%,虽然静态点云错误检测率升高 17.52%,但增值仅为 0.006 5;经上述量化验证,本文级联式架构凭借分层针对性处理,充分展现出兼顾检测精度和运算效率的优势。此外,如表 6 所示,随着稳定点云簇漏检比例增加,级联式架构的点云运动状态判断性能略有波动但整体保持稳定;其中,动态点云正确检测率最大降幅仅为 0.34%,静态点云错误检测率最大增值仅为 0.003 6,处理耗时呈逐渐升高趋势,有效验证了级联式判断架构对误差传递风险的可控能力,适配复杂场景下的实际应用需求。

4 结 论

本文提出一种稳健的级联式 LiDAR 点云运动状态判断方法,旨在高效精准地判别点云簇运动状态,以此剔除动态干扰,进而提升 LiDAR SLAM 定位性能。该方法通过构建 6 帧滑动窗口,并采用质心双重配准策略,针对独立点云簇分别生成时序连贯的运动状态判断向量,结合 LOF 离群检测与 DBSCAN 优化的 KDE 局部峰值分析,形成分层递进的级联式判断架构,同时引入动态追踪机制缩减运算开销。该方法不需要预构地图,且不依赖数据标注和高性能硬件,实测场景中相应动态点云正确检测率达到 0.928 2,静态点云错误检测率仅为 0.043 6,且面对不同体积、速率、位置目标特性时均展现出高精确性和强稳健性,单帧点云处理耗时 28.15 ms,完全满足 10 Hz 点云采集的实时处理需求。但是,在多目标密集重叠且持续遮挡情况下,局部峰值独立性和稳定性分析面临极端挑战,可能影响不稳定目标的运动状态判断精度。针对上述不足,在未来研究中将引入轻量级点云实例分割作为前置处理环节,以此对密集重叠区域的粘连点云进行更准确的独立点云簇拆分,并将拆分结果作为质心双重配准的输入,进而更稳健地支撑后续运动状态

判断特征构建以及级联式点云运动状态判断过程;在分析点云簇 X、Y 轴坐标峰值分布变化规律的基础上,综合考虑点云局部密度分布和轮廓几何形态的变化趋势,以增强峰值解析过程的抗扰动能力,同时充分保障处理效率,从而提升点云运动状态判断的整体性能。

参考文献

[1] Fan Z, Zhang L L, Wang X Y, et al. LiDAR, IMU, and camera fusion for simultaneous localization and mapping: A systematic review[J]. Artificial Intelligence Review, 2025, 58(6): 174.

[2] 蔺小虎, 杨鑫, 姚顽强, 等. 面向复杂地下空间的多源传感器数据动态加权融合 SLAM 方法[J]. 测绘学报, 2025, 54(3): 523-535.

Lin Xiaohu, Yang Xin, Yao Wanqiang, et al. A dynamic weighted fusion SLAM method using multi-source sensor data in complex underground spaces[J]. Acta Geodaetica et Cartographica Sinica, 2025, 54(3): 523-535.

[3] Xu X B, Zhang L, Yang J, et al. A review of multi-sensor fusion slam systems based on 3D LIDAR [J]. Remote Sensing, 2022, 14(12): 2835.

[4] Qian C L, Xiang Z H, Wu Z R, et al. RF-LIO: Removal-first tightly-coupled LiDAR inertial odometry in high dynamic environments[PP/OL]. V1. (2022-06-19) [2026-05-14]. <https://doi.org/10.48550/arXiv.2206.09463>.

[5] Chen X Y L, Milioto A, Palazzolo E, et al. Suma++: Efficient LiDAR-based semantic SLAM [C]//2019 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2019: 4530-4537.

[6] Schauer J, Nuchter A. The peopleremover-removing dynamic objects from 3-D point cloud data by traversing a voxel occupancy grid[J]. IEEE Robotics and Automation Letters, 2018, 3(3): 1679-1686.

[7] Lim H, Hwang S, Myung H. ERASOR: Egocentric ratio of pseudo occupancy-based dynamic object removal for static 3D point cloud map building[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 2272-2279.

[8] Zhou Z G, Feng X, Di S F, et al. A LiDAR mapping system for robot navigation in dynamic environments[J]. IEEE Transactions on Intelligent Vehicles, 2023, 1-20.

[9] Kim G, Kim A. Remove, then revert: Static point cloud map construction using multiresolution range images[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 10758-10765.

[10] Jia Y P, Wang T, Cao F K, et al. TRLO: An efficient

- LiDAR odometry with 3D dynamic object tracking and removal[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74:1-10.
- [11] Fan T X, Shen B W, Zhang Y Q, et al. S2MAT: Simultaneous and self-reinforced mapping and tracking in dynamic urban scenarios[J]. Journal of Field Robotics, 2026, 43(1): 454-485.
- [12] Tian X B, Zhu Z Y, Zhao J Q, et al. DL-SLOT: Tightly-coupled dynamic LiDAR SLAM and 3D object tracking based on collaborative graph optimization[J]. IEEE Transactions on Intelligent Vehicles, 2023, 9(1): 1017-1027.
- [13] Zhao S B, Fang Z, Li H L, et al. A robust laser-inertial odometry and mapping method for large-scale highway environments [C]//2019 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2019: 1285-1292.
- [14] Vaquero V, Fischer K, Moreno-Nogure F, et al. Improving map re-localization with deep ‘movable’ objects segmentation on 3D LiDAR point clouds [C]//2019 IEEE Intelligent Transportation Systems Conference, 2019: 942-949.
- [15] Chen X Y L, Li S J, Mersch B, et al. Moving object segmentation in 3D LiDAR data: A learning-based approach exploiting sequential data[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 6529-6536.
- [16] Li B, Zhang T L, Xia T. Vehicle detection from 3D LiDAR using fully convolutional network[PP/OL]. V1. (2016-08-29) [2026-05-14]. <https://doi.org/10.48550/arXiv.1608.07916>.
- [17] Pfreundschuh P, Hendrikx H F C, Reijgwart V, et al. Dynamic object aware lidar slam based on automatic generation of training data[C]//2021 IEEE International Conference on Robotics and Automation, 2021: 11641-11647.
- [18] Levinson J, Thrun S. Unsupervised calibration for multi-beam lasers [C]//2014 The 12th International Symposium on Experimental Robotics, 2014: 179-193.
- [19] Hong S, Ko H, Kim J. VICP: Velocity updating iterative closest point algorithm [C]//2010 IEEE International Conference on Robotics and Automation, 2010: 1893-1898.
- [20] Fan W W, Liu X Y, Zhang Y J, et al. Airborne LiDAR point cloud filtering algorithm based on supervoxel ground saliency [J]. ISPRS Annals of the Photo-grammetry, Remote Sensing and Spatial Information Sciences, 2024, 10: 73-79.
- [21] Himmelsbach M, Hundelshausen F V, Wuensche H J. Fast segmentation of 3D point clouds for ground vehicles[C]//2010 IEEE Intelligent Vehicles Symposium, 2010: 560-565.
- [22] Xu A G, Gao J X, Sui X, et al. LiDAR dynamic target detection based on multidimensional features [J]. Sensors, 2024, 24(5):1369.
- [23] Li M L, Liu Q, Peng S. Point cloud registration based on concave hull association[J]. Remote Sensing Letters, 2023, 14(3): 313-322.
- [24] 董泽, 贾昊. 基于 EWT-LOF 的热工过程数据异常值检测方法[J]. 仪器仪表学报, 2020, 41(2): 126-134.
- Dong Ze, Jia Hao. Outlier detection method for thermal process data based on EWT-LOF[J]. Chinese Journal of Scientific Instrument, 2020,41(2):126-134.
- [25] Mattera G, Mattera R, Vespoli S, et al. Anomaly detection in manufacturing systems with temporal networks and unsupervised machine learning[J]. Computers & Industrial Engineering, 2025, 203: 111023.
- [26] 陈啸轩, 邹阳, 翁祖辰, 等. 基于 IKNN 和 LOF 的变压器回复电压数据清洗方法研究[J]. 电子测量与仪器学报, 2024, 38(2): 92-100.
- Chen Xiaoxuan, Zou Yang, Weng Zuchen, et al. Recovery voltage data cleaning method for transformer based on IKNN and LOF [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(2): 92-100.
- [27] Choi J, Kim J, Im S. Robust TDOA estimation using kernel density estimation for noisy environments [C]//2025 IEEE International Conference on Consumer Electronics, 2025: 1-5.
- [28] 郭远晶, 魏燕定, 金晓航, 等. 基于 S 变换谱核密度估计的齿轮故障诊断[J]. 仪器仪表学报, 2017, 38(6): 1432-1439.
- Guo Yuanjing, Wei Yanding, Jin Xiaohang, et al. Gear fault diagnosis based on kernel density estimation of S transform spectrum [J]. Chinese Journal of Scientific Instrument, 2017, 38(6): 1432-1439.
- [29] 王跃飞, 于炯, 苏国平, 等. ODIC-DBSCAN: 一种新的簇内孤立点分析算法 [J]. 自动化学报, 2019, 45(11): 2107-2127.
- Wang Yuefei, Yu Jiong, Su Guoping, et al. ODIC-

- DBSCAN: A new analytical algorithm for inliers [J]. Acta Automatica Sinica, 2019, 45(11): 2107-2127.
- [30] 刘宇, 余学祥, 谢世成, 等. 改进 DBSCAN 聚类的信道状态信息定位算法 [J]. 电子测量技术, 2022, 45(7): 169-173.
- Liu Yu, Yu Xuexiang, Xie Shicheng, et al. Channel state information localization based on improved DBSCAN clustering algorithm [J]. Electronic Measurement Technology, 2022, 45(7): 169-173.
- [31] Yin L F, Hu H T, Li K P, et al. Improve-ment of DBSCAN algorithm based on K-dist graph for adaptive determining parameters [J]. Electronics, 2023, 12(15): 3213.
- [32] Satopaa V, Albrecht J, Irwin D, et al. Finding a "kneedle" in a haystack: Detecting knee points in system behavior [C]//2011 31st International Conference on Distributed Computing Systems Workshops, 2011: 166-171.
- [33] Behley J, Garbade M, Milioto A, et al. Semantickitti: A dataset for semantic scene understanding of lidar sequences [C]//2019 IEEE/CVF International Conference on Computer Vision, 2019: 9297-9307.
- [34] Wen W S, Zhou Y Y, Zhang G H, et al. UrbanLoco: A full sensor suite dataset for mapping and localization in urban scenes [C]//2020 IEEE Inter-national Conference on Robotics and Automation, 2020: 2310-2316.

作者简介



E-mail: gao_jx9903@163.com

Gao Jiaxin received his B. Sc. degree in 2021 and his M. Sc. degree in 2024 from Liaoning Technical University. He is currently pursuing his Ph. D. degree in surveying and mapping science and technology at the same University. His main research interests include smart cities, LiDAR SLAM, and autonomous driving.



E-mail: suixin@lntu.edu.cn

Sui Xin (Corresponding author) received his B. Sc. degree in 2004 and his M. Sc. degree in 2007 from Liaoning Technical University, and his Ph. D. degree in 2017 from Wuhan University. He is currently an associate professor at Liaoning Technical University. His main research interests include GNSS and indoor-outdoor seamless positioning.

高佳鑫, 2021 年于辽宁工程技术大学获得学士学位, 2024 年于辽宁工程技术大学获得硕士学位, 现于辽宁工程技术大学攻读测绘科学与技术专业博士学位, 主要研究方向为智慧城市、LiDAR SLAM、自动驾驶。

隋心 (通信作者), 2004 年于辽宁工程技术大学获得学士学位, 2007 年于辽宁工程技术大学获得硕士学位, 2017 年于武汉大学获得博士学位, 现为辽宁工程技术大学副教授, 主要研究方向为 GNSS、室内外无缝定位。