

HRegNet-LO: 基于端到端深度神经网络的 LiDAR 里程计测量

付永健, 李宗春*, 何华, 王力, 李丛

战略支援部队信息工程大学地理空间信息学院, 河南 郑州 450001

摘要 针对传统 LiDAR 里程计(LO)测量方法在处理无初值、长序列点云配准时存在精度低、稳定性差等问题,本文引入端到端点云配准网络(HRegNet),提出一种基于深度神经网络的 LO 测量方法——HRegNet-LO 算法,以期实现更加准确、鲁棒的 LO 测量。所提算法由两个核心模块组成:前端计算和后端优化。在前端 scan-to-scan 配准中,主要是依据原始点云的 3D 坐标,采用 HRegNet 网络,计算出相邻两帧点云的初始转换矩阵,实现 LO 初始位姿计算;在后端 scan-to-map 配准中,主要是通过提取特征点构建特征地图,应用迭代最近邻点(ICP)算法,每间隔一定距离对初始位姿进行优化,以减小预估轨迹中的漂移。在 Kitti odometry 数据集上对所提算法的性能进行了评估,并与 LOAM、F-LOAM 等算法作对比分析。实验结果表明,所提算法相对旋转、平移误差分别在 $0.003^\circ/\text{m}$ 和 1% 左右,每帧位姿计算耗时约为 100 ms,可以满足 LO 测量对于精度和实时性的要求。

关键词 HRegNet 网络; LiDAR 里程计; 特征地图; 迭代最近邻点; Kitti odometry 数据集

中图分类号 TP701 **文献标志码** A

DOI: 10.3788/AOS230548

1 引言

在无人驾驶系统中,车辆里程计扮演着重要角色,其主要任务是测定车辆的位置和方向,无需额外辅助信息[例如全球导航卫星系统(GNSS)定位信息],仅依靠自身局部传感器即可感知车辆所在位置,可在 GNSS 信号弱或噪声较大的情况下,提供比 GNSS 测量结果更加准确、可靠的车辆位姿信息^[1]。车辆里程计主要分为视觉里程计(VO)^[2-3]和 LiDAR 里程计(LO)^[4-7]两类,VO 在应用过程中受限于光照条件,而 LO 通过主动发射激光束,不受光照变化的影响,从而使 LO 较 VO 更适用于车辆里程计测量任务。

LO 算法通常包含前端计算和后端优化两部分,前端一般采用高频的 scan-to-scan 配准方式,实现相邻帧转换关系的快速计算,获得一定精度的载体运动轨迹;后端一般采用低频的 scan-to-map 配准方式,将当前帧配准到不断扩展的地图上,以获得更加精确的载体运动轨迹。无论是 LO 算法的前端计算还是后端优化,其核心都是点云配准,根据点云配准所应用的数据类型,可将 LO 测量分为基于特征和基于扫描两类算法。

基于特征的 LO 算法中最具代表性是 Zhang 等^[5-6]提出的 LO 和地图构建(LOAM)方法,该算法包含三

个核心模块,分别是特征提取与匹配、LO 计算和 LiDAR 地图构建。首先,从输入点云中提取边缘特征点和平面特征点,以此作为配准基元;然后,在一个 10 Hz 高频线程上运行 LO 前端模块,采用 scan-to-scan 配准方式计算点云帧相对运动;最后,在另一个 1 Hz 低频线程上运行 LO 后端模块,维护局部地图,通过 scan-to-map 匹配方式优化前端位姿估计结果。虽然 LOAM 算法在室内、外场景中展现出了优异性能,但仍存改进空间。为降低其计算复杂度,Shan 等^[7]提出了轻量级的 LOAM (LeGO-LOAM),通过改进特征提取和采用两步优化配准方案,降低了系统运算量;但该算法要求 LiDAR 系统必须严格水平安装在载体上,以更好地区分地面点和非地面点,并且在无高质量惯性测量单元(IMU)等第三方辅助数据时,系统会产生较大的漂移。为更充分地利用获取的 LiDAR 点云信息, Park 等^[8]将点云强度引入 LOAM 算法,有效提高了算法在 Kitti odometry 数据集^[9]上的表现,位置和姿态精度分别提升了 4.1% 和 4.8%,但耗时增加了约一倍。Wang 等^[10]为提升 LOAM 算法效率,提出了 F-LOAM 算法,在前端计算中假设载体保持匀速直线运动,依据前 1 帧位姿推算后 1 帧位姿,在后端优化中采用和 LOAM 相同的方法;F-LOAM 可实现高达 20 Hz 的前端计算,但其测量精度较 LOAM 算法有所降低。

收稿日期: 2023-02-14; 修回日期: 2023-03-15; 录用日期: 2023-03-22; 网络首发日期: 2023-05-08

基金项目: 国家自然科学基金(42071454)

通信作者: *13838092876@139.com

除上述算法外,一些工作还试图引入除 LiDAR 系统以外的模块以提高算法性能,例如 Shan 等^[11]将 IMU 和 GNSS 融合到 LO 算法中,提高了快速旋转场景(例如手持设备)和室外环境下的定位精度。本文主要关注仅依靠 LiDAR 系统的 LO 测量算法,基于第三方辅助数据的方法,可以参考文献[12-13]。

基于扫描的 LO 算法依据配准过程中所使用的基元,可进一步分为基于点对应关系和基于分布对应关系的 LO 算法。基于点对应关系的代表性算法是迭代最近邻点(ICP)^[14]及其拓展算法^[15],主要通过 ICP 算法计算相邻两帧转换关系,进而实现 LO 测量。基于分布对应关系的典型算法是正态分布变换(NDT)^[16]及其改进算法^[17],主要应用 NDT 配准点云以计算 LO 值。基于扫描的 LO 算法,由于使用完整的扫描点云计算转换关系,耗时较为严重,例如 IMLS-SLAM 算法^[15]每帧配准耗时约为 1.25 s、PNDDT-LO 算法^[17]约为 0.2 s,难以满足 10 Hz 的实时性要求。

除上述传统的 LO 算法外,在过去几年中,也有一些深度学习相关的工作尝试使用卷积神经网络(CNN)进行 LO 测量。例如, Yin 等^[18]提出了基于深度学习的无监督卷积自编码器特征点选择规则,随后匹配提取到的特征点完成 LO 测量,学习到的高级特征能有效提升匹配成功率。目前基于端到端深度神经网络

的 LO 算法的相关研究依然较少,为此,本文将端到端点云配准网络(HRegNet)^[19]引入 LO 前端计算,并借鉴 LOAM 算法后端优化思想,通过构建特征地图,实现 LO 算法后端优化,提出基于 HRegNet 深度神经网络的 LO 测量方法——HRegNet-LO 算法,以期实现快速、准确的 LO 测量。

2 HRegNet-LO 算法

本文所提方法包括两个核心模块,分别是前端计算和后端优化,计算流程如图 1 所示。前端计算主要依赖 HRegNet 深度神经网络^[19]和 ICP 算法^[14]实现相邻两帧 scan-to-scan 配准,注重效率,能以 10 Hz 实时地计算出具有一定精度的每帧点云位姿信息;后端优化基于特征点间的平差完成 scan-to-map 配准,关注精度,主要是通过构建特征地图,在前端计算的基础上,每间隔 10 帧,将当前帧与特征地图进行匹配,优化位姿计算结果。

2.1 特征点提取

借鉴 LOAM 算法^[6]中特征点提取方法,基于每个采样点的曲率信息提取特征点,包括基于近邻点的曲率信息计算和基于采样点曲率信息的特征点提取两个关键步骤。

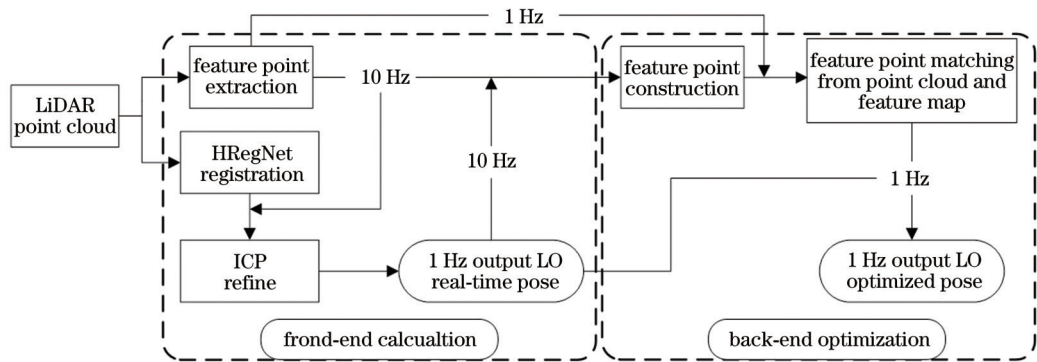


图 1 HRegNet-LO 算法流程图

Fig. 1 Flow chart of HRegNet-LO algorithm

2.1.1 曲率信息计算

采用 LOAM 算法^[6]中曲率计算方法,对每帧点云中的每个采样点,在其同一条扫描线上沿前后方向各选取 n 个近邻点(文中将 n 设定为 5),依据下式计算其曲率信息:

$$c = \left[\sum_{i=1}^n (p_i[x] - p[x])^2 \right] + \left[\sum_{i=1}^n (p_i[y] - p[y])^2 \right] + \left[\sum_{i=1}^n (p_i[z] - p[z])^2 \right], \quad (1)$$

式中: p 表示当前采样点; $p[x]$ 、 $p[y]$ 、 $p[z]$ 分别表示点 p 沿 3 个坐标轴的分量; c 表示点 p 的曲率; p_i 表示点 p 的第 i 个近邻点。

2.1.2 特征点选取

该步骤主要是依据每个点的曲率信息,从每帧点云中挑选出尖锐特征点、平滑特征点和平面特征点共三类特征点,供后续特征地图构建和 scan-to-map 特征匹配使用。首先,对每帧点云中的点按曲率排序;然后,选取曲率最大的 10 个点记为尖锐特征点 F^c ,选取曲率最小的 20 个点记为平面特征点 F^p ,在剩余点中依据曲率均匀选取 100 个点记为平滑特征点 F^s 。如图 2 所示,为某帧点云特征点提取结果。

2.2 前端计算

包含 HRegNet 配准、ICP 精化和序列配准三个重要步骤。首先将相邻两帧点云输入到具有上百万个神经元的 HRegNet 成对点云配准网络^[19]中,仅依靠 3D



图 2 某帧点云特征点提取结果

Fig. 2 Feature points extraction result of a point cloud

坐标,实现无初值情况下的配准;然后通过特征点提取模型,分别挑选出具有显著特征的三种类型特征点;随后在 HRegNet 配准的基础上,通过 ICP 算法迭代两帧点云中相同类型的特征点,精化转换关系;最后,通过序列配准方式,计算出每帧点云在第 1 帧坐标系下的初始位姿,即 LO 前端计算。

2.2.1 HRegNet 配准

该网络针对输入的相邻 2 帧点云(源点云 P^S 和目标点云 P^T),通过在训练数据集上学习到的知识,预测一个旋转矩阵 R 和一个平移向量 t ,然后依据式(2)构建一个转换矩阵 T ,以很好地将 P^S 转换到 P^T 坐标系下。该网络流程如图 3 所示,对其更为详细的介绍,请参考文献[19]。

$$T = \begin{bmatrix} R & t \\ 0 & 1 \end{bmatrix}. \quad (2)$$

2.2.2 ICP 精化

为使相邻两帧点云更好地融合在一起,以减少其

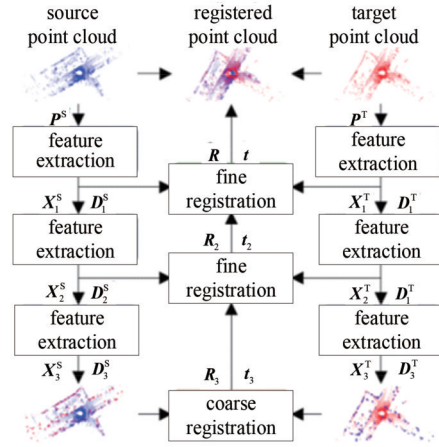


图 3 HRegNet 配准网络流程图^[19]

Fig. 3 Flow chart of HRegNet registration network^[19]

在长序列配准中的误差累积,在 HRegNet 计算结果的基础上,应用 ICP 算法迭代两帧点云中相同类型的特征点,对上一步计算结果进行精化,以求得更加准确的转换关系。

将前 1 帧点云中三类特征点分别记为 ${}^T F^c$ 、 ${}^T F^p$ 、 ${}^T F^s$,后 1 帧的记为 ${}^S F^c$ 、 ${}^S F^p$ 、 ${}^S F^s$,HRegNet 网络计算的两帧点云转换矩阵记为 T_{ini} ;随后,应用 T_{ini} 转换特征点集 ${}^S F^c$ 、 ${}^S F^p$ 、 ${}^S F^s$,得到其在前 1 帧点云坐标系下的对应点集 ${}_{T_1}^S F^c$ 、 ${}_{T_1}^S F^p$ 、 ${}_{T_1}^S F^s$;然后,将特征点集 ${}_{T_1}^S F^c$ 、 ${}_{T_1}^S F^p$ 、 ${}_{T_1}^S F^s$ 和 ${}^T F^c$ 、 ${}^T F^p$ 、 ${}^T F^s$ 输入到 ICP 算法中,通过迭代的方式,依据式(3)求解精化转换矩阵 ΔT 。

$$\Delta T = \frac{ICP({}_{T_1}^S F^c, {}^T F^c) + ICP({}_{T_1}^S F^p, {}^T F^p) + ICP({}_{T_1}^S F^s, {}^T F^s)}{3}. \quad (3)$$

最后,通过下式求解后 1 帧点云配准到前 1 帧的转换矩阵 T_{i-1}^i :

$$T_{i-1}^i = \Delta T \cdot T_{ini}, \quad (4)$$

式中: T_{i-1}^i 表示第 i 帧点云配准到第 $i-1$ 帧的转换矩阵; T_{ini} 为应用 HRegNet 网络计算的初始转换矩阵; ΔT 为通过 ICP 算法计算出的精化转换矩阵。

2.2.3 序列配准

经过上述处理,已获取连续 LiDAR 点云中相邻两帧间较为准确的转换矩阵,即可以此为依据,通过序列配准的方式[如式(5)所示],计算每帧点云在第 1 帧坐标系下的位姿信息,即如图 1 所示的前端计算的输出信息。

$$T_1^n = T_{n-1}^n \cdot T_{n-2}^{n-1} \cdots T_{i-1}^i \cdots T_2^3 \cdot T_1^2, \quad (5)$$

式中: T_1^n 表示第 n 帧点云在第 1 帧坐标系下的位姿,即 LO 测量值; T_{i-1}^i 表示第 i 帧与第 $i-1$ 帧间的转换矩阵。

2.3 后端优化

通过前端计算,已求得较高精度的 LO 初始位姿,

但由于长序列连续配准中累积误差的存在,使 LO 测量结果存在漂移现象。本步骤主要工作就是采用基于特征匹配的调整策略,通过 scan-to-map 配准方式,每间隔 10 帧对前端计算的位姿信息进行优化调整,以期减弱 LO 测量结果中的漂移。包含特征地图构建、特征点匹配和位姿优化共三个核心环节。

2.3.1 特征地图构建

依据前端计算得到的每帧点云位姿信息,将当前帧(第 n 帧)之前的所有帧点云中的特征点融合在一起,定义为当前帧所对应的特征地图。第 n 帧 LiDAR 点云所对应的特征地图可通过下式计算得到:

$$\text{map}_{n-1} = \sum_{i=1}^{n-1} T_i \cdot F_i, \quad (6)$$

式中: map_{n-1} 表示第 n 帧对应的特征地图; $F_i = \{F^c, F^p, F^s\}$ 为第 i 帧中的特征点; T_i 为第 i 帧初始位姿。

2.3.2 特征点匹配

首先,将特征地图中每种类型的特征点分别存储到相应的KD-Tree结构中,以提高后续步骤中近邻点搜索的效率。

然后,针对当前帧中的特征点 $F_n = \{F_n^c, F_n^p, F_n^s\}$,依据初始位姿 T_1^n ,对其进行坐标转换,转换后的特征点集记为 $T_1^n F_n = \{T_1^n F_n^c, T_1^n F_n^p, T_1^n F_n^s\}$ 。

(a)



(b)




图 4 特征点匹配结果示意图。(a) 点集 $T_1^n F_n$; (b) 点集 F_{map}

Fig. 4 Illustration of feature points matching. (a) Point set $T_1^n F_n$; (b) point set F_{map}

2.3.3 位姿优化

采用与式(3)中类似的方式,将特征点匹配结果输入到ICP算法中,通过迭代的方式计算出优化转换矩阵 ΔT ;随后依据式(7)调整前端计算的第 n 帧位姿信息,即可得到如图1所示的后端计算结果。

$$T_1^n = \Delta T \cdot T_1^n. \quad (7)$$

位姿信息更新完毕之后,依据第 n 帧位姿 T_1^n ,将其包含的特征点融合到特征地图之中,构建第 $n+1$ 帧对应的特征地图 map_n ,以便后续位姿调整过程中使用。

3 实验与分析

为更好地测试、分析 HRegNet-LO 算法的性能,在 Kitti odometry^[9] 数据集上进行实验,并与 ICP^[14]、HRegNet^[19]、LOAM^[6] 和 F-LOAM 算法^[10] 作对比分析。所有算法均在一台装有 Ubuntu20.04 系统 [Intel

随后,应用最近邻搜索算法,为 $T_1^n F_n = \{T_1^n F_n^c, T_1^n F_n^p, T_1^n F_n^s\}$ 中每种类型中的每个特征点,在特征地图 map_{n-1} 中相应类型的特征点集中为其寻找最近的 5 个近邻点,记为集合 $F_{\text{map}} = \{F_{\text{map}}^c, F_{\text{map}}^p, F_{\text{map}}^s\}$,将集合 $T_1^n F_n = \{T_1^n F_n^c, T_1^n F_n^p, T_1^n F_n^s\}$ 和 $F_{\text{map}} = \{F_{\text{map}}^c, F_{\text{map}}^p, F_{\text{map}}^s\}$ 视为特征点匹配结果。如图 4 所示,为某组数据集中特征点匹配结果。

(R) Xeon (R) E-2176G CPU 3.70 GHz 64.0-GB RAM] 的计算机上完成,其中,ICP 算法应用 Python 语言基于 Open3D 开源库实现;LOAM 和 F-LOAM 算法通过在机器人操作系统 (ROS) 下调试原文作者公开的源码实现;HRegNet 和 HRegNet-LO 算法应用 Python 语言基于 PyTorch 实现,深度神经网络在 NVIDIA RTX 3090 GPU 上进行训练,初始学习率设为 0.001,每 10 个周期下降 50%,训练周期设为 50。

3.1 实验所用数据集

Kitti odometry^[9] 是用于测试 LO 算法的公开数据集,由 22 个子序列组成,其中前 11 个序列 (00~10) 包含地面真实位姿信息。在本文实验中,使用序列 00~05 进行训练,序列 06 和 07 用于验证,序列 08~10 用于测试。表 1 描述了实验所用数据集的详细信息。

表 1 实验所用数据集详细信息

Table 1 Details of experimental datasets

Seq	Frame	Length / m	Max speed / (km·h ⁻¹)	Seq	Frame	Length / m	Max speed / (km·h ⁻¹)
00	4541	3724	46	06	1101	1232	51
01	1101	2453	96	07	1101	694	39
02	4661	5067	49	08	4071	3222	43
03	801	560	31	09	1591	1705	52
04	271	393	56	10	1201	919	51
05	2761	2205	40				

3.2 评价标准

采用 Geiger 等^[9] 提出的相对精度评估方法对本文涉及的 LO 测量算法进行评价。相对误差定义为一段距离区间内的相对位姿变化估值与地面真实值间的偏

差,包括相对旋转误差 (RRE) 和相对平移误差 (RTE)。RRE 单位为“(°)/m”,表示每米所包含的相对旋转误差;RTE 单位为“%”,表示每百米所包含的相对平移误差。计算公式为

$$\begin{cases} e_{\text{RRE}} = \frac{1}{|F|} \sum_{(F_i, F_j) \in F} \frac{\text{acos}\left\{\left\{\frac{\text{trace}\left[{}^{\text{et}}R_i^j\left({}^{\text{gt}}R_i^j\right)^{-1}\right]-1}{2}\right\}\right\} \cdot \frac{180}{\pi}}{\text{dis}\left(F_i, F_j\right)}, \\ e_{\text{RTE}} = \frac{1}{|F|} \sum_{(F_i, F_j) \in F} \frac{\|{}^{\text{et}}t_i^j - {}^{\text{gt}}t_i^j\|}{\text{dis}\left(F_i, F_j\right)} \end{cases}, \quad (8)$$

式中： F 表示一系列成对点云 (F_i, F_j) ， $|F|$ 表示其数量； ${}^{\text{gt}}R_i^j$ 和 ${}^{\text{gt}}t_i^j$ 分别表示第 j 帧与第 i 帧间的地面真实旋转矩阵和平移向量； ${}^{\text{et}}R_i^j$ 和 ${}^{\text{et}}t_i^j$ 分别表示由算法估计得到的旋转矩阵和平移向量； $\text{dis}(F_i, F_j)$ 表示两帧点云间的距离，可通过平移向量或者点云重心间距离计算； $\text{trace}(\Delta R)$ 表示矩阵 ΔR 的迹。

3.3 实验结果

图5展示了HRegNet-LO算法在3组测试数据集上的计算结果及真值沿 x 、 y 、 z 坐标轴分量的可视化

结果。

观察图5可以发现，HRegNet-LO算法测量结果沿 x 、 z 轴方向上的分量与地面真实位姿信息吻合得很好，沿 y 轴方向的测量精度较差，这是因为Kitti odometry数据集中提供的地面真实位姿信息是定义在车辆载体左相机坐标系下的，其 x 轴指向右、 y 轴指向下、 z 轴指向前，由车载LiDAR系统扫描获取的点云在水平方向（沿 x 、 z 轴方向）具有更多的约束，而在垂直方向（沿 y 轴方向）约束较少，因此水平方向的定位精度优于垂直方向。




图5 提出算法在测试数据集上的测量结果沿各坐标轴分量的可视化图。(a) 序列08；(b) 序列09；(c) 序列10

Fig. 5 Visualization of results of proposed algorithm on testing datasets along each coordinate axis. (a) Seq 08; (b) Seq 09; (c) Seq 10

在实际应用中，LO测量结果中沿水平方向的分量比垂直方向的更为重要，为了更加清晰地观察本文

所提算法在水平方向上的测量结果，图6展示了其在3组测试数据集上测量结果的鸟瞰图。




图6 提出算法在测试数据集上测量结果的鸟瞰图。(a) 序列08；(b) 序列09；(c) 序列10

Fig. 6 Aerial view of results of proposed algorithm on testing datasets. (a) Seq 08; (b) Seq 09; (c) Seq 10

分析图6可以发现，HRegNet-LO算法在3组测试数据集上的测量结果在水平方向上的分量都十分接近

地面真实路径，由此可以定性地说所提算法能有效实现实验数据中LO的测量工作，同时也验证了

HRegNet-LO 算法仅依靠 LiDAR 点云,通过 scan-to-scan 初始配准和 scan-to-map 位姿调整的方式,就可实现车辆等载体运动轨迹的准确计算。

3.4 对比分析

为了更加具体地分析 HRegNet-LO 算法的测量精度,表 2 记录了对比算法 LOAM、F-LOAM 和本文算

法在 3 组测试数据集上的测量精度及耗时情况,并统计了测量精度的均方根误差(RMSE),以及在 3 组测试数据集上计算每帧点云位姿耗时的平均值,表中加粗字体表示最优值;图 7 展示了 3 种算法在上述数据集上测量结果的固定距离相对误差曲线。

表 2 3 种算法在测试数据集上的测量精度及耗时统计
Table 2 Accuracy and time consuming of three algorithms on testing datasets

Algorithm	Accuracy and time consuming	Seq 08	Seq 09	Seq 10	RMSE
LOAM	RRE / [°·m ⁻¹]	0.0041	0.0031	0.0032	0.0035
	RTE / %	1.0569	0.7326	1.0706	0.9661
	Time consuming / ms	87	83	85	—
F-LOAM	RRE / [°·m ⁻¹]	0.0048	0.0051	0.0060	0.0053
	RTE / %	1.3532	1.2520	1.5218	1.3802
	Time consuming / ms	76	74	75	—
HRegNet-LO	RRE / [°·m ⁻¹]	0.0033	0.0031	0.0039	0.0035
	RTE / %	1.0472	0.7190	1.0480	0.9508
	Time consuming / ms	95	97	96	—




图 7 3 种算法在测试数据集上的固定距离相对误差。(a) 序列 08; (b) 序列 09; (c) 序列 10

Fig. 7 Fixed distance relative errors of three algorithms on testing datasets. (a) Seq 08; (b) Seq 09; (c) Seq 10

分析表 2 和图 7 所示信息可以发现,在 3 组测试数据集上,就 RRE 和 RTE 而言(测量精度),本文算法近乎取得了最优的 LO 测量结果,每百米的相对位姿误差可控制在 0.3° 和 1 m 左右,可以满足无人驾驶领域中对于载体定位精度的要求^[20]。

在计算耗时方面,上述 3 种算法地图更新频率均为 1 Hz,后端优化采用的策略大致相同,scan-to-map 配准耗时均约为 100 ms;在前端计算中,F-LOAM 算法最为高效,其 scan-to-scan 配准耗时约为 70 ms,LOAM 算法约为 80 ms,本文算法约为 90 ms,3 种算法均可满足 10 Hz 的实时定位要求。

综合上述两个方面(测量精度和耗时),HRegNet-LO 算法具有最高的测量精度,也最为耗时(但仍满足实时性要求)。所提算法在前端计算更为耗时的原因

是在 scan-to-scan 配准过程中,采用所有采样点计算相邻两帧转换关系,确保精度的同时,增加了计算量;而两种对比算法均是通过提取少量关键点进行配准,减小了计算量,提高了效率。在下一步工作中,可考虑设计一种特征点提取网络,从原始数据中挑选出部分关键点,以高效、高质量实现 scan-to-scan 配准。

3.5 消融实验

HRegNet-LO 算法分为前端计算和后端优化两部分,在前文实验中展示了整体计算结果,为更详细分析前端测量结果,在本小节进行消融实验。仅应用 HRegNet-LO 算法的前端(HRegNet-LO-odom)对 3 组实验数据集进行测量,并与 ICP (ICP-odom)、HRegNet 网络(HRegNet-odom)和 LOAM 算法前端(LOAM-odom)的 LO 测量结果进行对比。测量精度

如表 3 所示,表中加粗字体表示最优值。图 8 展示了 4 种算法的固定距离相对误差曲线。

表 3 消融实验测量结果
Table 3 Results of ablation experiments

Algorithm	Accuracy	Seq 08	Seq 09	Seq 10	RMSE
ICP-odom	RRE / [(°)·m ⁻¹]	0.0621	0.1177	0.0586	0.0840
	RTE / %	14.5136	31.0251	16.7450	22.0121
HRegNet-odom	RRE / [(°)·m ⁻¹]	0.0402	0.0161	0.0212	0.0278
	RTE / %	9.8344	3.7263	4.5524	6.6163
LOAM-odom	RRE / [(°)·m ⁻¹]	0.0211	0.0191	0.0182	0.0195
	RTE / %	4.9715	5.9807	3.8240	5.0036
HRegNet-LO-odom	RRE / [(°)·m ⁻¹]	0.0116	0.0099	0.0112	0.0109
	RTE / %	4.1401	2.4475	2.4555	3.1177

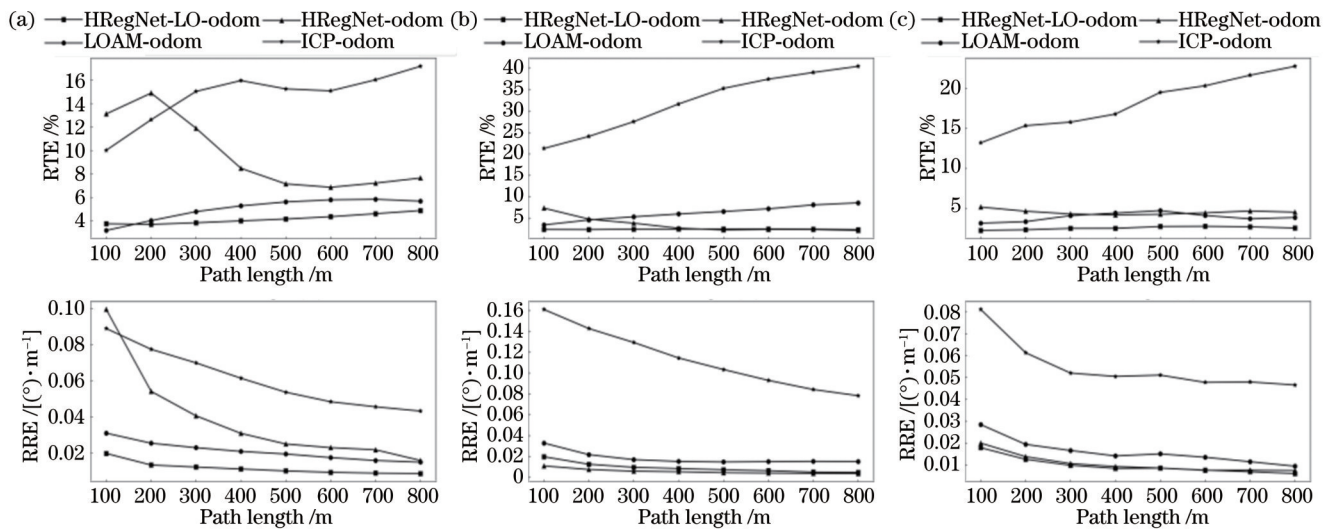


图 8 消融实验中各算法的固定距离相对误差。(a) 序列 08; (b) 序列 09; (c) 序列 10

Fig. 8 Fixed distance relative errors of algorithms in ablation experiments. (a) Seq 08; (b) Seq 09; (c) Seq 10

综合分析表 3 和图 8, 可以发现 3 点信息: 1) HRegNet-LO-odom 测量精度优于 HRegNet-odom 和 ICP-odom, 说明 HRegNet-LO-odom 采用 HRegNet+ICP 的计算方式, 可以得到比单一应用 HRegNet 网络或 ICP 算法更高的 LO 测量精度; 2) HRegNet-LO-odom 比 HRegNet-odom 精度提升了约 50%, 这得益于 HRegNet-LO-odom 在测量中实施了 ICP 精化; 3) HRegNet-LO-odom 测量精度优于 LOAM-odom, LOAM-odom 仅应用部分特征点计算 LO 初值, 少于 HRegNet-LO-odom 所用点数, 说明在 LO 前端计算过程中输入的数据量, 不仅影响计算速度, 也是决定测量精度的一个因素。

4 结 论

本文设计了一种应用 HRegNet 深度神经网络实现前端计算和应用点云特征地图实现后端优化的 LO 测量方法——HRegNet-LO 算法, 在 Kitti odometry 数据集上得到了良好的测试结果。在前端计算中, 每百米的相对旋转误差和相对平移误差分别在 1° 和 3 m 左

右, 每帧位姿计算耗时约为 90 ms, 可在满足实时性 (耗时小于 100 ms) 要求的条件下计算出具有较高精度的 LO 初始位姿; 经过后端优化之后 (每间隔 10 帧优化一次), 每百米的相对旋转精度和相对平移精度分别优于 0.4° 和 1.1 m, 每次优化耗时约为 100 ms, 可为 SLAM 等技术应用提供高精度载体位姿信息, 以实现高精度地图构建。

本文仅研究了基于 LiDAR 点云 3D 坐标的里程计测量, 为提高测量结果的可靠性和精度, 在后续研究中可考虑多系统融合方法, 如融合惯导、视觉和 LiDAR 里程计测量技术; 此外, 基于深度学习的点云配准方法的性能受训练数据的制约大, 在大量数据集上训练好神经网络后, 在同类型数据集上能表现出良好性能, 但在不同环境中, 如室内/室外和城市/乡村场景中, 其表现还不够稳定, 泛化性有待进一步提高。

参 考 文 献

- [1] 刘鹏飞. 里程计辅助的高精度车载 GNSS/INS 组合导航系统 [J]. 光学精密工程, 2020, 28(4): 979-987.
Liu P F. High-precision vehicle GNSS/INS integrated

- navigation system aided by odometer[J]. Optics and Precision Engineering, 2020, 28(4): 979-987.
- [2] 卢金, 刘宇红, 张荣芬. 面向动态场景的语义视觉里程计[J]. 激光与光电子学进展, 2021, 58(6): 0611001.
Lu J, Liu Y H, Zhang R F. Semantic-based visual odometry towards dynamic scenes[J]. Laser & Optoelectronics Progress, 2021, 58(6): 0611001.
- [3] 张再腾, 张荣芬, 刘宇红. 一种基于深度学习的视觉里程计算法[J]. 激光与光电子学进展, 2021, 58(4): 0415001.
Zhang Z T, Zhang R F, Liu Y H. Visual odometry algorithm based on deep learning[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0415001.
- [4] 秦正, 高向川, 陈政康, 等. 基于运动预测的改进激光里程计[J]. 激光与光电子学进展, 2023, 60(19): 1928004.
Qin Z, Gao X C, Chen Z K, et al. Improved Lidar odometer based on motion prediction[J]. Laser & Optoelectronics Progress, 2023, 60(19): 1928004.
- [5] Zhang J, Singh S. LOAM: lidar odometry and mapping in real-time[EB/OL]. [2022-11-09]. <https://www.roboticsproceedings.org/rss10/p07.pdf>.
- [6] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping[J]. Autonomous Robots, 2017, 41(2): 401-416.
- [7] Shan T X, Englot B. LeGO-LOAM: lightweight and ground-optimized lidar odometry and mapping on variable terrain[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2019: 4758-4765.
- [8] Park Y S, Jang H, Kim A. I-LOAM: intensity enhanced LiDAR odometry and mapping[C]//2020 17th International Conference on Ubiquitous Robots (UR), June 22-26, 2020, Kyoto, Japan. New York: IEEE Press, 2020: 455-458.
- [9] Geiger A, Lenz P, Urtasun R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, June 16-21, 2012, Providence, RI, USA. New York: IEEE Press, 2012: 3354-3361.
- [10] Wang H, Wang C, Chen C L, et al. F-LOAM: fast LiDAR odometry and mapping[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 27-October 1, 2021, Prague, Czech Republic. New York: ACM Press, 2021: 4390-4396.
- [11] Shan T X, Englot B, Meyers D, et al. LIO-SAM: tightly-coupled lidar inertial odometry via smoothing and mapping[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 24-January 24, 2021, Las Vegas, NV, USA. New York: IEEE Press, 2021: 5135-5142.
- [12] 何璇, 潘树国, 谭涌, 等. 室外环境下基于点线特征的视觉-惯性里程计和全球卫星导航系统定位算法[J]. 激光与光电子学进展, 2022, 59(18): 1815002.
He X, Pan S G, Tan Y, et al. Visual-inertial odometry and global navigation satellite system location algorithm based on point-line feature in outdoor scenes[J]. Laser & Optoelectronics Progress, 2022, 59(18): 1815002.
- [13] Júnior G P C, Rezende A M C, Miranda V R F, et al. EKF-LOAM: an adaptive fusion of LiDAR SLAM with wheel odometry and inertial data for confined spaces with few geometric features[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(3): 1458-1471.
- [14] 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.
- [15] Deschaud J E. IMLS-SLAM: scan-to-model matching based on 3D data[C]//2018 IEEE International Conference on Robotics and Automation (ICRA), May 21-25, 2018, Brisbane, QLD, Australia. New York: ACM Press, 2018: 2480-2485.
- [16] Magnusson M, Lilienthal A, Duckett T. Scan registration for autonomous mining vehicles using 3D-NDT[J]. Journal of Field Robotics, 2007, 24(10): 803-827.
- [17] Hong H, Lee B H. Probabilistic normal distributions transform representation for accurate 3D point cloud registration[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 24-28, 2017, Vancouver, BC, Canada. New York: IEEE Press, 2017: 3333-3338.
- [18] Yin D Y, Zhang Q, Liu J B, et al. CAE-LO: LiDAR odometry leveraging fully unsupervised convolutional auto-encoder for interest point detection and feature description[EB/OL]. (2020-01-06)[2022-11-09]. <https://arxiv.org/abs/2001.01354>.
- [19] Lu F, Chen G, Liu Y L, et al. HRegNet: a hierarchical network for large-scale outdoor LiDAR point cloud registration[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 15994-16003.
- [20] Reid T G R, Houts S E, Cammarata R, et al. Localization requirements for autonomous vehicles[EB/OL]. (2019-06-03)[2022-11-09]. <https://arxiv.org/abs/1906.01061>.

HRegNet-LO: LiDAR Odometry Measurement Based on End-to-End Deep Neural Network

Fu Yongjian, Li Zongchun*, He Hua, Wang Li, Li Cong

Institute of Geospatial Information, PLA Strategic Support Force Information Engineering University, Zhengzhou 450001, Henan, China

Abstract

Objective Vehicle odometer plays an important role in unmanned driving systems, and its main task is to determine the position and pose of the vehicle. The calculation method falls into two categories of visual odometry (VO) and LiDAR odometry (LO). VO is limited by illumination conditions, while LO is unaffected by illumination changes through active laser beam emission, making LO more suitable for vehicle odometry measurement than VO. However, the traditional LO algorithms face the problems of low accuracy and weak robustness when they are employed to register the continuous LiDAR frame point clouds without initial value and long sequence. We introduce an end-to-end point cloud registration

network HRegNet and propose an LO computation algorithm using deep neural networks HRegNet-LO. Such a LO computation strategy exhibits strong robustness, good accuracy, and high efficiency, and we hope that the proposed algorithm can be helpful to the LO measurement.

Methods The HRegNet-LO algorithm includes two core modules of front-end calculation and back-end optimization. The calculation is shown in Fig. 1.

In front-end calculation, scan-to-scan registration is conducted to obtain the transformation of adjacent two LiDAR frame point clouds. Firstly, HRegNet is employed to calculate a rough transformation matrix between two adjacent LiDAR frames without initial value by adopting the original point clouds. Secondly, according to point curvature, some feature points belonging to different categories are extracted from the original point clouds. Thirdly, the rough transformation matrix is refined by an iterative closest point (ICP) algorithm using feature points. Fourthly, LO initial pose is obtained by the sequence registration of the transformation matrix between two adjacent LiDAR frames.

In back-end optimization, scan-to-map registration is conducted to adjust the LO initial pose. Firstly, a feature map is constructed using the initial LO pose and feature points. Secondly, by finding the corresponding feature points from the current LiDAR frame and feature map, a pose correctional value is obtained via the ICP algorithm. Thirdly, the LO pose of the current LiDAR frame is adjusted to reduce the estimated trajectory drift.

Results and Discussions Comprehensive experiments are carried out on the Kitti odometry dataset to evaluate and demonstrate the performance of the proposed HRegNet-LO algorithm. The LOAM, F-LOAM, and some other methods are compared with our method.

Figures 5 and 6 show the qualitative results of HRegNet-LO on three experimental datasets. Figure 5 indicates that the measurement results of the HRegNet-LO algorithm along the x and z axes are in good agreement with the real pose information of the ground truth, while the measurement accuracy along the y axis is poor. This is because the point clouds obtained by the vehicle-mounted LiDAR system have more constraints in the horizontal direction (along the x and z axes), but fewer constraints in the vertical direction (along the y axis). Therefore, the positioning accuracy of the horizontal direction is better than that of the vertical direction. In practical applications, the horizontal component of LO measurement results is more important than the vertical component. To observe the horizontal measurement results of the proposed algorithm more clearly, Fig. 6 shows the aerial view of our algorithm's measurement results on the three testing datasets, where we can find that the horizontal component of the measured results is very close to the real path of the ground-truth. To conclude, the proposed algorithm can accurately realize the LO measurement only by LiDAR point clouds.

Quantitative and comparison experiments are also conducted, whose results are shown in Fig. 7 and Table 2. In terms of relative rotation error (RRE) and relative translation error (RTE), our method almost obtains the best LO measurement results, and the RRE and RTE per 100 m can be controlled at about 0.3° and 1 m respectively, which can meet the positioning accuracy requirements in unmanned driving.

Ablation experimental results are shown in Fig. 8 and Table 3, which show that the back-end optimization can improve the accuracy by about 70%.

Conclusions We design a novel LO measurement method HRegNet-LO algorithm. The front-end calculation is realized by HRegNet deep neural network, and back-end optimization is realized by point clouds feature map. Experimental results show that the RRE and RTE of HRegNet-LO are about $0.003^\circ/\text{m}$ and 1% respectively, and the consumed time of calculating each frame pose is about 100 ms. The proposed method can satisfy the accuracy and real-time requirements in LO measurement. However, we only consider using 3D coordinates of LiDAR point clouds to achieve LO measurement. Multi-system fusion methods such as integrated inertial navigation, vision, and LiDAR odometer measurement technology can be considered in subsequent studies to improve the reliability and accuracy of LO measurement results. Meanwhile, the generalization of deep neural networks also should be improved.

Key words HRegNet network; LiDAR odometry; feature map; iterative closest point; Kitti odometry dataset