

DOI: 10.19650/j.cnki.cjsi.J2413302

基于隐式神经地图的 LiDAR/IMU 匹配定位算法^{*}

高 旺, 赵 恒, 刘 宏, 潘树国, 黄飞璇
(东南大学仪器科学与工程学院 南京 210096)

摘 要:针对现有匹配定位算法依赖高内存且稠密点云地图的问题,提出基于隐式神经地图的激光雷达/惯性测量单元(LiDAR/IMU)融合匹配定位算法。首先,利用浅层感知机预测有向距离场构建轻量化及高分辨率的隐式神经地图;其次,通过点到隐式神经模型配准方法,实现基于轻量化隐式神经地图的低频状态估计。同时,针对单一激光雷达隐式配准过程中难以应对激进运动的问题,引入 IMU 预积分方法为隐式配准提供状态估计预测值,以减少配准过程的迭代次数;最后,基于因子图融合激光里程计因子和 IMU 预积分因子,实现鲁棒的高频状态估计。在 KITTI 数据集、实测室内走廊及室外校园环境下的实验结果表明,所构建的隐式神经地图内存占用相较于传统点云地图可减少 87%,实现更轻量化的地图表示;在 KITTI 数据集中,提出的激光雷达隐式配准算法定位精度相比传统 NDT 算法提高了 43.4%;引入 IMU 后,该融合算法定位精度相比 NDT-IMU 算法提高了 60%;在室内和室外校园实测数据中,也验证了算法在小场景下的厘米级实时定位能力。同时分析得出,IMU 的引入使得隐式神经地图配准耗时大幅减少,显著提升了地图匹配定位的实时性。

关键词: 隐式神经表征;轻量化地图;先验地图;匹配定位

中图分类号: TP242.6 TH76 **文献标识码:** A **国家标准学科分类代码:** 510.80

LiDAR/IMU matching localization algorithm based on implicit neural map

Gao Wang, Zhao Heng, Liu Hong, Pan Shuguo, Huang Feixuan

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: Aiming at the problem that existing matching localization algorithms rely on high-memory and dense point cloud map, a light detection and ranging (LiDAR)/inertial measurement unit (IMU) matching localization algorithm based on an implicit neural map is proposed. Firstly, a lightweight and high-resolution implicit neural map is constructed using a shallow perceptron to predict the signed distance field. Secondly, low-frequency state estimation based on the lightweight implicit neural map is realized through a point and implicit neural model registration method. Meanwhile, to address the challenge of handling aggressive motion during single LiDAR implicit registration, an IMU pre-integration method is introduced. This provides predictive state estimation for implicit registration, reducing the number of iterations required during the registration process. Finally, robust high-frequency state estimation is realized by fusing the LiDAR odometry factor and IMU pre-integration factor based on the factor graph. Experimental results in the KITTI dataset, as well as in real-world indoor corridor and outdoor campus environments, demonstrate the effectiveness of the proposed algorithm. The memory usage of the implicit neural map is reduced by 87% compared to traditional point cloud maps, enabling a more lightweight map representation. In the KITTI dataset, the proposed LiDAR implicit registration algorithm improves the positioning accuracy by 43.4% compared to the traditional normal distributions transform (NDT) algorithm. Furthermore, the fusion algorithm, which incorporates IMU data, achieves a 60% improvement in positioning accuracy compared to the NDT-IMU algorithm. The centimeter-level real-time positioning capability of the proposed algorithm in small scenes is also verified in both practical indoor and outdoor campus. Meanwhile, analysis reveals that the integration of IMU significantly reduces the computational time required for implicit neural map registration, effectively enhancing real-time localization performance.

Keywords: implicit neural representation; lightweight map; prior map; matching localization

收稿日期: 2024-09-22 Received Date: 2024-09-22

^{*} 基金项目: 国家重点研发计划(2021YFB3900804)项目资助

0 引 言

近年来,随着自动驾驶技术的迅猛进步,移动机器人在工业生产乃至日常生活中的作用更加重要,而状态估计是智能无人系统运行的先决条件,也一直是机器人和数字测绘等领域的热点研究方向^[1]。激光雷达(light detection and ranging, LiDAR)因其测距范围广,能够提供全视角的三维环境的几何信息,并且不受光照和弱纹理特征环境的影响,成为自主移动机器人的重要组成部分^[2-3]。利用激光雷达进行定位,主要包括激光雷达同时定位与建图(simultaneous localization and mapping, SLAM)和点云地图匹配定位两种模式。其中,SLAM 模式是一种相对定位手段,在大场景中定位结果容易产生误差的累积和漂移,难以实现长航时鲁棒定位^[4-5];点云地图匹配定位则是依赖先验地图的全局定位模式,能够获得误差不随时间和距离累积的绝对定位信息。在复杂城市环境、室内及地下空间中,全球导航卫星系统定位失效,基于先验地图的激光雷达匹配定位技术为绝对定位数据来源提供了一个有效的替代方案,激光雷达当前帧点云数据与地图的配准是其中的核心关键问题^[6]。

早期二维激光雷达匹配定位的研究采用了概率占用栅格地图^[7],并使用基于迭代最近点(iterative closest point, ICP)算法^[8]或粒子滤波方法^[9]进行状态估计,通常应用于小型且结构化的室内环境^[10]。对于三维激光雷达匹配定位技术,Zhang 等^[11]开创性地提出从扫描点云中提取稀疏的平面或者边缘特征点,并使用 ICP 算法将特征配准到特征点云地图中,实现实时的点云配准定位。Shan 等^[12]在后端以因子图方式融合了惯性测量单元(inertial measurement unit, IMU)预积分因子并采用关键帧选择策略,实现更高精度的激光雷达匹配定位。Xu 等^[13]又以滤波方式实现快速鲁棒的状态估计。为了避免 ICP 算法中计算搜索最近邻匹配点的时间消耗,正态分布变换^[14](normal distributions transform, NDT)算法将点云转换成多维变量的正态分布,仅计算点云在所属网格中的概率分布函数数值实现匹配定位,减少时间消耗的同时,也保持了定位准确性,被广泛应用于机器人导航定位方案中^[15]。除了经典的 ICP 与 NDT 配准方法,还有一些基于学习的激光雷达匹配方法^[16-18],利用端到端姿态监督方案实现相邻帧之间的配准,但模型的前期训练和部署需要消耗大量的算力资源,暂无法在算力一般的计算平台上实时运行。

此外,现有的点云匹配算法通常依赖于稠密且高内存占用的显式点云地图,难以适用于大规模环境;同时,大多数移动机器人在设备上执行计算的内存和算力也较

为有限。因此,点云地图应该紧凑轻量及足够精确,以详细表征环境。近几年来,隐式神经表征^[19]的相关研究展现出比广泛使用的显式点云表征具有优势,主要表现在更轻量化的存储、更好的噪声平滑能力以及更高分辨率和连续的场景表示,在三维重建领域得到广泛研究^[20-21]。针对传统激光雷达建图方法面临内存消耗和建图精度问题,Zhong 等^[22]在 2023 年提出了适用于激光雷达隐式神经地图的建图方法,该方法基于体素八叉树结构来学习和存储隐式特征,输入到多层感知机(multi-layer perceptron, MLP)中预测有向距离场(signed distance field, SDF),构建轻量的隐式神经地图。随后,Wiesmann 等^[23]根据隐式神经表示方法,提出了激光点云与隐式模型的配准算法,但该方法的隐式模型直接通过点云三维数据和神经网络构建,忽略了环境中可学习的隐式特征,神经网络层数多,导致建图和配准耗时长,仅适用于小范围环境。Deng 等^[24]提出了在大规模场景中基于体素特征网格的隐式神经表示的激光雷达 SLAM 方法,该算法利用八叉树体素结构动态嵌入隐式特征,结合神经网络构建神经距离函数,通过最小化有向距离值误差,同时优化地图和位姿。该方法对计算资源需求大,难以实时运行和应用。Pan 等^[25]提出了基于点的隐式神经表示的激光雷达 SLAM 方法。该方法将体素特征网格替换为具有弹性且可优化神经点,实现了更轻量化的地图表示及融合回环检测构建全局一致的地图,但是该隐式神经模型在实时定位时需要较长时间进行在线训练和优化。

综上,考虑目前隐式的激光雷达定位和建图算法受到隐式神经地图在线训练耗时长和 SLAM 定位产生累积漂移的影响,本文针对先验地图模式,提出基于先验隐式神经地图的激光雷达匹配定位算法。利用先验隐式神经地图轻量化和连续表示的特点,通过点到隐式神经模型配准方法,实现鲁棒和高精的无漂移状态估计。同时,为克服单一激光雷达隐式配准过程中难以应对激进运动和迭代收敛耗时问题,引入 IMU 预积分估计,为隐式配准提供状态估计预测值,以提高配准效率。最后,基于因子图实现实时高频状态估计。

1 LiDAR/IMU 隐式神经地图匹配定位算法

1.1 总体框架

图 1 为基于隐式神经地图的 LiDAR/IMU 匹配定位算法总体框架,由地图训练模块、数据预处理模块和里程计模块 3 部分组成。地图训练模块首先输入当前帧位姿真值和激光点云,利用匀速模型对运动点云进行去畸变。其次,沿着从激光雷达中心到点云 P_k 中每个点的射线进行采样,并使用真值位姿 T_{wL_k} 将采样点变换到世界系。




图1 基于隐式神经地图的LiDAR/IMU匹配定位算法总体框架

Fig. 1 General framework of LiDAR/IMU matching localization algorithm based on implicit neural map

接着,使用近表面样本 C_s 来初始化新的神经点,将它们添加到全局神经地图 M 中,并以当前位姿 T_{WL_k} 为中心,重置局部神经地图 M_k 。使用当前帧的训练样本 C 更新训练样本池,并将样本池中的样本以批量优化的方式输入到 SDF 解码器中,通过梯度下降法优化局部地图 M_k 的神经点特征。最后,将更新后的局部神经地图 M_k 分配回全局神经地图 M 。

数据预处理模块输入当前帧激光雷达点云 P_i 和 IMU 的加速度 a_i 和角速度 ω_i , 利用 IMU 预积分方法对运动点云进行畸变矫正,矫正后的点云通过均匀降采样方法,降采样为稀疏的待配准点云 P_i' , 保持配准精度的同时减少冗余点云计算时间。其次,IMU 在上一帧优化后的位姿基础上进行累积积分,为当前帧配准位姿优化求解提供初值 $\hat{T}_{WL_i}$, 减少优化算法的迭代次数。最后,将 IMU 在激光雷达两帧之间的相对位姿量测 $\Delta T_{WL_{i-1}}^* \hat{T}_{WL_i}$ 作为预积分因子加入到位姿图 G 中,作为帧间约束。

里程计模块使用位姿初值 $\hat{T}_{WL_i}$ 将待配准点云 P_i' 变换到世界系下,并以当前位姿为中心,重置局部神经地图 M_i 。其次,将当前帧待配准点云和局部地图中的最近邻神经点联合,构建出点云中每一点的特征值和相对距离,输入到 SDF 解码器中,输出得到点云中每一点的有向距离残差,通过列文伯格-马夸尔特方法迭代收敛,估计最优全局位姿 $T_{WL_i}^*$ 。最后,将激光里程计因子添加到位姿图 G 中,作为先验约束。

1.2 隐式神经地图表征与构建方法

1) 隐式神经地图表示

构建先验隐式神经地图是地图匹配定位的前提。

隐式神经地图由一组神经点构成:

$$M = \{m_i = (x_i, q_i, f_i, t_i) \mid i = 1, \dots, N\} \quad (1)$$

式中: $x_i \in \mathbf{R}^3$ 表示每个神经点 m_i 在世界系 W 中的位置; $q_i \in \mathbf{R}^4$ 表示神经点自身坐标系方向的四元数; t_i 表示神经点创建与更新的时间; 每个神经点存储可优化的潜在特征向量 $f_i \in \mathbf{R}^f$, 代表局部几何形状, f 为自定义潜在特征向量维数。神经点的潜在特征向量表示了点云中的局部几何信息,输入到浅层神经网络中训练优化,以最大程度地捕捉点云几何特征。每个神经点 m_i 与传感器位姿 T_{WL_i} 关联,在 t_i 时刻,通过更新传感器位姿直接变换神经地图。

2) SDF 解码器

如图 2 所示, SDF 解码器^[26]将当前帧点云与地图邻近神经点组合成包含潜在特征值和相对距离的向量,输入到浅层的 MLP 神经网络中,映射得到 SDF 预测值,即当前点到地图环境表面的距离。解码器将学习到的环境特征转换为一种更直接和更易解释的有向距离场形式,以便进行神经地图训练和点云隐式配准。




图2 SDF 解码器

Fig. 2 SDF decoder

SDF 解码器根据附近 k 个神经点预测位置 $\mathbf{p}$ 的有向距离场值 s 。对于查询位置 $\mathbf{p}$ 的每一个邻近神经点 $\mathbf{m}_i$, 首先将神经点位置 $\mathbf{x}_i$ 与 $\mathbf{p}$ 连接, 得到相对坐标 d_i 。接着将特征值 $\mathbf{f}_i$ 和相对坐标 d_i 组成并集向量, 输入到一个全局神经点共享的浅层神经网络 F 中, MLP 包含了两层的隐藏层和输入的神经点的特征向量, 以预测有向距离场值 s_i :

$$s_i = F(\mathbf{f}_i, d_i) \quad (2)$$

$$d_i = \mathbf{q}_i(\mathbf{x}_i - \mathbf{p})\mathbf{q}_i^{-1} \quad (3)$$

然后通过反距离加权将查询位置 $\mathbf{p}$ 处的最近 k 个神经点的预测 SDF 值合并为最终的预测 $s = S(\mathbf{p})$:

$$S(\mathbf{p}) = \sum_{i \in k} \frac{\lambda_i}{\sum_{j \in k} \lambda_j} s_i \quad (4)$$

$$\lambda_i = \|\mathbf{x}_i - \mathbf{p}\|^{-2} \quad (5)$$

3) 地图训练样本和损失优化

在构建训练数据集过程中, 对于每个时刻 t_i , 都沿着激光雷达点云 P_t 的射线采集样本。射线采样侧视图如图 3 所示, 激光雷达测量的是传感器原点到被测点 $\mathbf{p}$ 的距离, 称为射线距离 d , 定义射线方向 $\mathbf{r} = \mathbf{p} / \|\mathbf{p}\|_2$ 。利用射线深度 d 和射线方向 $\mathbf{r}$ 表示激光雷达系 L_t 中的采样点 $\mathbf{o}$, 即 $\mathbf{o} = \mathbf{r} \cdot d$ 。定义接近表面的 N_s 个采样点为 $\mathbf{o}_s$, 其深度服从高斯分布 $d_s \sim \mathcal{N}(\|\mathbf{p}\|_2, \sigma_d^2)$ 。为了更全面地采样, 在表面前方的自由空间中均匀采样 N_f 个采样点 $\mathbf{o}_f$, 深度 $d_f \sim \mathcal{U}(\|\mathbf{p}\|_2 - \sigma_d, \|\mathbf{p}\|_2 - 2\sigma_d)$, 及表面后方深度为 $d_b \sim \mathcal{U}(\|\mathbf{p}\|_2 + \sigma_d, \|\mathbf{p}\|_2 + 2\sigma_d)$ 的 N_b 个采样点 $\mathbf{o}_b$ 。对于每个采样点 $\mathbf{o}$, 其 SDF 目标值为 $\bar{s} = \|\mathbf{p}\|_2 - d$, 表示当前采样点到环境表面的真实距离, 用于监督训练 MLP 神经网络和地图神经点特征。




图 3 LiDAR 射线采样侧视图

Fig. 3 Side view of LiDAR ray sampling

在 t_i 时刻, 训练样本 C 由 N_t 个采样点和对应的 SDF 目标值构成:

$$C = \{(\mathbf{o}_j, \bar{s}_j) \mid j = 1, \dots, N_t\} \quad (6)$$

式中: $N_t = R_t(1 + N_s + N_f + N_b)$; R_t 为激光雷达点云 P_t 中的射线总数。

构建隐式神经地图的目标是通过训练地图中神经点潜在的几何特征来预测任意位置的 SDF 值, 并且这些神经点特征需要增量地从训练样本池 C 中批量随机采样进

行训练, 使用的损失函数结合了二元交叉熵 (binary cross entropy, BCE) 损失和 Eikonal 正则化损失。在世界系中的样本表示为 $\mathbf{o}_w^j = \mathbf{T}_{wL_j} \mathbf{o}_L^j$, 输入该样本的 SDF 预测值 $s_j = S(\mathbf{o}_w^j)$ 和目标值 $\bar{s}_j$, 计算 N 个样本的 BCE 损失:

$$L_{\text{bce}} = \frac{1}{N} \sum_{j=1}^N \bar{s}_j \cdot \log(s_j) + (1 - \bar{s}_j) \cdot \log(1 - s_j) \quad (7)$$

由于 MLP 神经网络的输出是有向距离值, 而 SDF 在截断区域内可微且等于 1, 因此添加 Eikonal 损失来加强拟合有向距离场的规律性和有效性:

$$L_{\text{eikonal}} = \frac{1}{N} \sum_{j=1}^N \left(\left\| \frac{\partial S(\mathbf{o}_w^j)}{\partial \mathbf{o}_w^j} \right\|_2 - 1 \right)^2 \quad (8)$$

最终损失函数为:

$$L = L_{\text{bce}} + \alpha_{\text{eik}} L_{\text{eikonal}} \quad (9)$$

式中: α_{eik} 为损失的权重。由于 Eikonal 损失为约束性损失, 参考文献[25]可知, 其损失权重一般设置为 0.5。在训练过程中, 通过优化地图中所涉及的神经点潜在特征来最小化损失函数。

1.3 点到隐式模型配准算法

在激光雷达点云的预处理模块, 利用了均匀体素降采样方法对激光雷达点云稀疏化处理。该方法将点云分割成固定尺寸大小的体素立方体, 然后将每个体素内的点替换为其质心, 从而减少点的数量。在保证点云纹理结构的同时, 也能够去除冗余点云, 提高计算效率。本文算法中待配准的点云体素降采样值设为 0.8 m。

在里程计模块中 (图 1), 首先由激光雷达采集当前帧点云, 利用位姿初值 $\hat{\mathbf{T}}_{wL_t}$ 变换到世界系下得到待配准点云 P_t^w , 将每一个点输入到 SDF 解码器中, 并以当前位姿初值为中心加载先验局部神经地图 M_t , 输出每一个点的有向距离值 SDF, 即当前点到环境表面的距离值。当所有点输出的 SDF 值为零或者绝对和 < 设定阈值时, 表明当前帧点云配准到先验的隐式神经地图上, 得到最优位姿。

如图 4 所示, SDF 解码器将局部隐式神经地图转为更直观的有向距离场。其中, 浅色为环境表面外部区域, 距离为正, 该位置的 $SDF > 0$; 深色为环境表面内部区域, 距离为负, 该位置的 $SDF < 0$; 圆点表示当前帧激光点云, 不断优化激光雷达位姿, 使得当前帧点云在有向距离场中的 SDF 值尽可能为 0, 即点云在环境表面上。与传统点云的离散表示相比, 有向距离场表示使得环境表征更加连续和精确。

点到隐式模型配准方法的目标是通过寻找最优的旋转矩阵 $\mathbf{R}^*$ 和位置向量 $\mathbf{t}^*$, 最小化当前帧点云处的 SDF 预测的距离误差, 便能将点云对齐到隐式神经地图中:

$$\mathbf{R}^*, \mathbf{t}^* = \underset{\mathbf{R}, \mathbf{t}}{\operatorname{argmin}} \sum_{\mathbf{p}_j \in P} S(\mathbf{t} + \mathbf{R}\mathbf{p}_j)^2 \quad (10)$$

式 (10) 非线性最小二乘问题使用列文伯格-马夸尔




图4 点云配准示意图

Fig. 4 Diagram of point cloud registration

特方法来求解,其中位姿初值由匀速模型或者 IMU 预积分估计提供。

每一个点 p_j 的雅可比为:

$$J_i = \left[\frac{\partial S(t + R p_j)}{\partial t}, \frac{\partial S(t + R p_j)}{\partial \Theta} \right] = \begin{bmatrix} \mathbf{v}_j^T, ((t + R p_j) \times \mathbf{v}_j)^T \end{bmatrix} \quad (11)$$

式中: $\Theta = \log(R)$ 是 R 的轴角表示; $\mathbf{v}_j = \partial S(p_w^j) / \partial p_w^j$ 是 p_w^j 处的距离梯度。

与经典的基于 ICP 配准方法相比,如式(10)和(11)所示,该方法不需要寻找点与环境的对应关系,只需要通过计算移动方向 $\mathbf{v}$ 和距离 $S(p_w^j)$ 来解决配准问题。该信息直接编码在 MLP 神经网络和隐式神经地图中。

对于每一次迭代,增量 $\delta \xi$ 如下式:

$$\delta \xi = (J^T P J + \lambda_{lm} I)^{-1} J^T P e \quad (12)$$

式中: $\delta \xi = [\delta t, \delta \Theta]$ 为位姿的李代数形式; P 为协方差矩阵; e 为残差向量; λ_{lm} 为阻尼因子。

在迭代完成后,对 $J^T P J$ 矩阵进行特征值计算,来评估算法的退化情况^[27]。若最小特征值 $\lambda_{\min} >$ 设定阈值 λ_{set} ,则配准成功。否则,直接使用匀速模型或者 IMU 预积分提供的位姿初值。

1.4 因子图优化

定义待优化的状态变量 $\mathbf{x}$ 为:

$$\mathbf{x} = [R^T, t^T, \mathbf{v}^T, \mathbf{b}^T]^T \quad (13)$$

式中: $R \in \text{SO}(3)$ 为旋转矩阵; $t \in \mathbb{R}^3$ 为位置向量; $\mathbf{v} \in \mathbb{R}^3$ 为速度向量; $\mathbf{b} = [b_a, b_\omega] \in \mathbb{R}^6$ 包含 IMU 的加速度和角速度偏置。

IMU 预积分是计算激光雷达两帧之间的相对运动。根据预积分公式^[28],可得 IMU 预积分约束为:

$$\mathbf{r}_B(B_i^{i+1}, X) =$$

$$\begin{bmatrix} r_t \\ r_q \\ r_v \\ r_{b_a} \\ r_{b_\omega} \end{bmatrix} = \begin{bmatrix} t_{ub_{i+1}} - t_{ub_i} - \mathbf{v}_i^w \Delta t + \frac{1}{2} \mathbf{g}^w \Delta t^2 - q_{ub_i} \alpha_{b_i b_{i+1}} \\ 2[\gamma_{b_i b_{i+1}}^* \otimes (q_{ub_i}^* \otimes q_{ub_{i+1}}^*)]_{xyz} \\ \mathbf{v}_{i+1}^w - \mathbf{v}_i^w + \mathbf{g}^w \Delta t - q_{ub_i} \beta_{b_i b_{i+1}} \\ b_{i+1}^a - b_i^a \\ b_{i+1}^\omega - b_i^\omega \end{bmatrix} \quad (14)$$

式中: IMU 坐标系定义为 b 系; $\alpha_{b_i b_{i+1}}$ 、 $\gamma_{b_i b_{i+1}}$ 、 $\beta_{b_i b_{i+1}}$ 为两帧之间运动的观测值。

利用点到隐式模型配准得到的激光雷达位姿,构建激光里程计约束,加入到因子图中:

$$\mathbf{r}_L(L_i^{i+1}, X) = \Delta T_{L_i, L_{i+1}} - T_i^{-1} T_{i+1} \quad (15)$$

因子图优化的目的是利用激光雷达和 IMU 的观测数据来优化机器人的状态和轨迹,该状态估计问题等价于求解一个非线性最小二乘问题,目标函数为:

$$\text{argmin}_X \left\{ \sum_{i=0} \|\mathbf{r}_L(L_i^{i+1}, X)\|^2 + \sum_{i=0} \|\mathbf{r}_B(B_i^{i+1}, X)\|^2 \right\} \quad (16)$$

2 实验验证与分析

2.1 实验过程

实验利用 KITTI 数据集^[29]评估本文算法在大规模城市环境和高速动态环境下的定位精度及地图的轻量化,利用室内和校园环境实测数据验证本文算法在小范围场景的高精度定位能力和实时性。进一步地,分析了地图中神经点特征向量对定位精度的影响。最后,利用旋转运动和变速运动验证了本文算法在激进运动模式下的稳定性。

本文硬件实验平台如图 5(a)所示,该平台采用松灵 HUNTER 阿克曼底盘作为运动平台,搭载速腾聚创 32 线激光雷达和工业级六轴 IMU。主控制器为 Jetson AGX Orin,操作系统为 Ubuntu 20.04,算法基于 ROS 平台运行, GPU 为 NVIDIA 4070 Ti SUPER。



(a) 无人车
(a) Unmanned vehicle

(b) 手持测绘仪
(b) Handheld mapping instrument

图5 硬件设备

Fig. 5 Hardware diagram

在 KITTI 数据集实验中,先验点云地图由每一帧激光点云和对应轨迹真值拼接而成;先验隐式神经地图由激光点云和轨迹真值共同训练生成。在实测数据集实验中,先验点云地图由华测 RS10 激光雷达三维测绘仪分别在室外融合差分定位建图及在室内利用全站仪测量基准

坐标建图,测绘仪如图 5(b)所示;无人车平台的参考轨迹由 NDT-IMU 和 ICP 点云配准算法与测绘级先验点云地图后处理生成,利用该参考轨迹和激光点云构建出先验隐式神经地图。在新场景中,若没有参考轨迹,也可基于同时定位和建图方法构建隐式神经地图,但基于 SLAM 方法的定位和建图的精度相较于采用参考轨迹建

图的精度略有下降。

2.2 KITTI 数据集实验验证

为了验证本文算法在大规模场景和高速动态物体干扰环境下的定位精度,本文采用 KITTI 数据集中的 6 个数据序列作实验验证,包含了简单到复杂的典型场景。各算法评估结果如表 1 所示,采用 RMSE 作为定位的评估指标。

表 1 KITTI 数据集中各算法的定位 RMSE 误差

Table 1 Position RMSE error for each algorithm in the KITTI dataset (m)

算法	使用数据	配准方法	KITTI 00	KITTI 02	KITTI 05	KITTI 06	KITTI 07	KITTI 09
PIN-SLAM	LiDAR	隐式神经	6.38	11.77	0.78	1.49	0.77	3.03
NDT	LiDAR+先验地图	正态分布	—	0.91	0.33	1.13	0.28	0.32
INR (本文算法)	LiDAR+先验地图	隐式神经	0.41	0.59	0.25	0.33	0.24	0.27
LIO-SAM-MAP		特征点云	—	—	0.29	0.17	0.24	0.27
NDT-IMU	LiDAR+IMU+先验地图	正态分布	0.42	0.61	0.32	0.26	0.23	0.26
INR-IMU (本文算法)		隐式神经	0.33	0.14	0.10	0.07	0.16	0.06

注:表格中符号“—”表示该算法在数据序列中定位失败;算法对比中较优的结果用加粗表示。

将本文提出的基于隐式神经地图的激光雷达匹配定位算法简称为 INR 算法,将融合 IMU 传感器的隐式模型匹配定位算法简称为 INR-IMU 算法。选取了不同优异的算法与本文算法进行实验对比。PIN-SLAM 算法是基于隐式神经地图的同时定位和建图算法,其在后端融合了回环检测模块,能够实现全局一致定位和建图。NDT 地图匹配定位算法将点云数据转为体素内的正态分布表示,利用正态分布配准估计点云之间的空间关系。在此基础上,NDT-IMU 算法进一步融合惯导数据,被广泛应用于移动机器人导航定位。LIO-SAM-MAP 算法是基于特征点云地图的匹配定位算法,该算法在经典的 LIO-SAM 算法基础上融合了先验地图模块,在前端利用广义的线面 ICP 算法,将提取的特征点云与先验地图配准,并在后端基于因子图融合 IMU 预积分因子。

由表 1 可知,对比单一的激光雷达定位效果,基于隐式神经配准的 PIN-SLAM 算法在该数据中的定位精度最低,这是由于其仅使用激光雷达数据,并且 SLAM 模式,随着地图范围的扩大,不可避免地产生累积误差,在大规模场景 KITTI 02 数据集中,PIN-SLAM 算法的定位累积误差最为明显。在 KITTI 00 数据集中,NDT 算法难以应对载体高速旋转的行驶状态发生定位漂移而导致定位失败;而 INR 算法在实现鲁棒定位的同时也保持了较高的精度,平均定位精度达到 0.34 m,相较于 NDT 算法提升 43.4% (基于 NDT 可定位的序列统计)。其原因是本文提出的 INR 算法通过隐式神经地图和 SDF 解码器,可以实现不依赖点云对应关系的点到隐式模型配准,从而避免了离散点云几何配准的精度损失,实现较高的配准精度。

对比 LiDAR/IMU 融合定位效果,在 KITTI 00 和

02 数据集中,LIO-SAM-MAP 算法采用的特征点云匹配算法难以应对特征稀疏以及大量动态物体环境导致定位失败,在其余数据序列中定位精度良好。NDT-IMU 算法和 INR-IMU 算法均利用了惯导数据对激光点云进行去畸变处理以及为配准算法提供位姿初值,均实现了鲁棒的定位性能。NDT-IMU 算法在该数据序列中的平均定位精度为 0.35 m,而 INR-IMU 算法的平均定位精度为 0.14 m,相较于 NDT-IMU 算法平均定位精度提升 60%。点到隐式模型配准算法由于融合了 IMU 数据能够应对更激进的高速运动,在 KITTI 数据序列中,平均定位精度相较于单一的激光雷达隐式配准算法提升 58.8%。

KITTI 02 序列路程为 5 km,各算法的轨迹对比如图 6 所示。从图 6 可以看出,PIN-SLAM 算法轨迹随着路程的增加,产生较大的累积误差,与真值轨迹在整体上存在明显偏离;NDT 算法轨迹在转弯处与真值轨迹存在较大偏差,并具有明显波动;INR 算法轨迹与真值轨迹也有较小的偏差,相比 NDT 算法轨迹偏差更小。NDT-IMU 算法和 INR-IMU 算法轨迹与真值轨迹均偏差极小,这是由于两者




图 6 KITTI 02 中各算法轨迹对比

Fig. 6 Comparison of algorithmic trajectories in KITTI 02

都利用了惯导数据为激光点云配准提供位姿初值,有效解决高速旋转状态下的定位精度低和鲁棒性问题。

KITTI 09 序列路程为 1.7 km,各算法轨迹对比如图 7 所示,三维方向上的定位误差如图 8 所示。从图 7 和 8 可以看出,PIN-SLAM 算法轨迹与真值轨迹的偏移程度最大,并且由于其定位误差过大,不与其他匹配定位算法一同评估三维方向的定位误差。NDT 算法轨迹明显偏离真值轨迹,在误差图中波动范围大。INR 算法在轨迹上略优于 NDT 算法,但与真实轨迹仍有偏差,并且在三维方向的误差图中具有明显的波动和偏差。3 类 LiDAR/IMU 融合定位算法相较于单一的激光雷达定位算法的定位精度有所提升,三维方向上的误差波动明显减小,其中 INR-IMU 算法在轨迹上更加接近真值轨迹,在三维方向上的误差波动最小,RMSE 误差达到了 0.06 m,在各类算法中具有最优的定位性能。




图 7 KITTI 09 中各算法轨迹对比

Fig. 7 Comparison of trajectories in KITTI 09




图 8 KITTI 09 中各算法定位误差

Fig. 8 Positioning errors of algorithms in KITTI 09

2.3 实测数据集实验验证

为了验证本文算法在实际小场景中的高精度定位能力,在室内廊道和室外校园两个场景中进行实验验证,场景中有上下坡和动态物体等干扰。各算法的定位误差评估如表 2 所示,PIN-SLAM 算法在小范围场景下实现了亚米级定位结果,而其他的地图匹配定位算法在能正常定位时段,均取得了厘米级的定位结果。但 NDT 算法在室外校园场景中,由于难以应对激进的旋转运动导致局部时段定位失败。LIO-SAM-MAP 算法融合了惯导数据,在室外校园场景中的旋转运动状态下实现了定位,但是该算法前端采用了特征点云配准方法,需要在激光点云中提取线面特征,然而室内的长直道走廊环境线特征稀疏,特征匹配算法失效导致定位失败。本文提出的基于隐式神经地图的激光雷达匹配定位算法在室内走廊和室外校园中均实现了较高的定位精度,同时也实现了较好的定位鲁棒性。

表 2 实测数据集中各算法的位置 RMSE 误差

Table 2 Position RMSE error for each algorithm in the practical dataset (m)

算法	室内廊道	室外校园
PIN-SLAM	0.53	0.57
NDT	0.03	—
INR	0.03	0.07
LIO-SAM-MAP	—	0.07
INR-IMU	0.02	0.04

室内廊道中的各算法轨迹对比如图 9 所示。PIN-SLAM 算法轨迹在整体上与真值轨迹具有明显的偏移。LIO-SAM-MAP 算法由于走廊特征退化影响定位失败,无定位轨迹。在转弯处,NDT 算法和 INR 算法的轨迹与真值轨迹有较大的偏差,而融合惯导数据的 INR-IMU 算法的轨迹与真值轨迹偏差较小。

图 10 和 11 所示分别为室外校园环境中各算法的轨迹对比情况和三维方向上的定位误差。PIN-SLAM 算法轨迹在终点处与真值轨迹具有明显偏差,由于其定位误差较大,不与其他匹配定位算法一同评估三维方向的定位误差。由于 NDT 算法在激进的旋转运动下定位失败,没有定位轨迹以及三维方向的定位误差评估。从定位轨迹和定位误差图中可以看出,INR-IMU 算法在 X 和 Y 方向上的误差均趋于 0,且波动较小,实现了更优的定位结果。但是在 Z 方向上,各类算法的定位误差波动较大,这是因为地面上的激光点云数<空间中的激光点云数,在配准算法中产生的高程约束不足,导致高程误差较大。




图 9 室内廊道中各算法轨迹对比

Fig. 9 Comparison of trajectories in indoor corridor




图 10 室外校园中各算法轨迹对比

Fig. 10 Comparison of trajectories in outdoor campus




图 11 室外校园中各算法定位误差

Fig. 11 Positioning errors in outdoor campus

2.4 地图内存占用和算法实时性评估

为了验证隐式神经地图的轻量化,本文选取了具有代表性的大规模城市场景、室内走廊及室外校园环境作

为实验验证,各类型地图内存占用结果如表 3 所示。原始点云地图是未降采样的稠密点云地图,内存占用极大,难以在定位算法中使用。NDT 算法所用的点云地图是由原始点云地图降采样得到,降采样率为 0.1 m,但是仍然需要百兆的内存占用,室内廊道的点云地图如图 12(b)所示,地图由离散的三维点云构成,利用稠密的点云表示,尽可能捕捉环境细节和占用信息,导致点云地图对内存占用的需求较大。而隐式神经地图的内存占用在大规模环境下仅需 109.4 MB,在小型环境下仅需 0.7 MB,相比 NDT 点云地图的平均内存占用减少了 87%,具有地图内存占用轻量化特点。隐式神经地图可视化如图 12(a)所示,地图由稀疏的神经点组成,神经点中包含了局部几何环境的特征信息,利用有向距离场神经网络,可以查询环境表面及周围的任意位置和占用率,提高了地图表示的分辨率和有效降低了地图信息的内存占用。

表 3 各地图内存占用

Table 3 Memory usage of each map (MB)				
地图类型	KITTI 02	KITTI 09	室内廊道	室外校园
原始点云地图	6 701.1	2 264.7	265.0	203.9
NDT 点云地图	880.1	327.3	17.3	90.5
隐式神经地图	109.4	46.8	0.7	14.4




图 12 室内廊道地图

Fig. 12 Indoor corridor map

为了验证提出的算法的实时性,本文在选取的典型数据序列中对 INR 和 INR-IMU 算法进行耗时评估,算力平台为 NVIDIA 4070 Ti SUPER。结果如表 4 所示,两个算法在室内廊道场景的每一帧激光点云所用时间如图 13 所示。从表 4 可以看出,INR 算法每帧点云处理平均耗时为 168 ms,不满足实时性需求。这是因为点到隐式模型的配准也需要一个良好的位姿初值进行迭代优化,当迭代未收敛时,需要更多的迭代次数。而引入 IMU 数据,为点到隐式模型配准提供准确初值,可以有效减小优化的迭代次数,从而降低运行时间。INR-IMU 算法每帧点云处理平均耗时为 83 ms,相比 INR 算法耗时降低了 50.6%,满足 10 Hz 定位实时性要求。

表 4 每帧点云处理耗时

Table 4 Point cloud processing time per frame (ms)

算法	KITTI 02	KITTI 09	室内廊道	室外校园
INR	247	130	145	152
INR-IMU	94	84	76	80




图 13 室内廊道中每帧点云处理耗时

Fig. 13 Time consuming point cloud processing per frame in indoor corridor

2.5 不同特征向量维数下的定位精度评估

在地图训练模块中,每个神经点的特征向量储存了学习到的局部环境的几何参数,特征向量的维数表示可优化的参数的数量。将该特征值输入到神经网络中,输出当前点到环境表面的最近距离,为点到隐式神经地图配准构建约束。为了研究神经点的特征向量对定位精度的影响,首先基于 4 个典型数据集,在不同特征向量维数下构建隐式神经地图。其次,评估了 INR 算法在不同特征向量维数下的定位精度。最后,评估了不同特征向量维数下模型内存占用的大小。

INR 算法在不同特征向量维数下的定位精度如表 5 所示。当神经点的特征向量仅有两个可优化变量时,INR 算法在 3 个大范围场景的数据集中无法进行连续定位,并且在小场景下的室内廊道中定位精度也明显降低,故使用较少的两个参数只能有限地学习到环境的几何表示。当特征向量维数为 4 时,定位精度在部分数据集下优于仅有两个参数变量时的情况,但在 KITTI 02 和室外校园中仍无法实现有效定位。当特征向量维数为 8 时,INR 算法在 4 个典型的场景中实现了鲁棒定位以及较优的定位精度。随着特征向量维数的提升,INR 算法的定位精度略有提高。虽然更高的特征维数能够学习到更多的几何参数,但是较高的特征向量维数并不能有效的表达简单的非结构化场景,反而过多的特征参数变量对计算产生了影响,因此 INR 算法在 64 维的特征向量下难以进行高精定位。

不同特征向量维数下的特征模型内存占用大小如图 14 所示。随着特征向量维数的增加,特征向量参数需要存储在特征模型中,模型内存占用也随着特征向量

表 5 不同特征维数下 INR 算法定位误差

Table 5 Positioning error of INR algorithm with different feature dimensions (m)

特征向量维数	KITTI 02	KITTI 09	室内廊道	室外校园
2	—	—	0.06	—
4	—	0.28	0.05	—
8	0.59	0.27	0.03	0.07
16	0.55	0.26	0.03	0.06
32	1.63	0.29	0.03	0.06
64	—	0.28	0.03	0.07




图 14 模型占用大小

Fig. 14 Model memory footprint

维数的增加而大幅增大。因此,综合不同特征向量维数对定位精度和模型占用大小的影响,本文选择神经点的特征向量维数为 8。

2.6 激进运动模式下实验验证

为了验证提出的算法在激进运动模式下的定位精度和稳定性,本文设计了旋转运动实验和变速运动实验来评估本文算法的定位精度、运行效率和轨迹结果。旋转运动实验在环境中作绕圈、急刹以及倒车运动。变速运动数实验在室外校园中作加速和减速运动,平均速度为 1.4 m/s,最大速度为 2.5 m/s,以及在该场景中包含了大量的行人和车辆等动态物体。

在激进运动模式下的定位误差和每帧点云耗时如表 6 所示。

表 6 激进运动模式下各算法的定位误差和耗时

Table 6 Positioning error and time consumption of each algorithm in aggressive motion mode

运动模式	旋转运动 定位误差/m	变速运动 定位误差/m	旋转运动每 帧耗时/ms	变速运动 每帧耗时/ms
INR	0.05	0.07	158	155
INR-IMU	0.02	0.03	85	81

运动轨迹分别如图 15 和 16 所示。INR 算法在激进运动模式下,仍保持了厘米级的定位精度。INR-IMU 算法

利用 IMU 预积分为隐式神经配准提供初值,来应对激进的旋转和变速运动,显著提高了定位精度和定位效率。




图 15 旋转运动轨迹

Fig. 15 Trajectory of rotational motion




图 16 变速运动轨迹

Fig. 16 Trajectory of variable-speed motion

3 结 论

针对现有激光雷达匹配定位算法依赖高内存且稠密的点云地图问题,本文提出基于先验隐式神经地图的 LiDAR/IMU 匹配定位算法。首先,利用神经点和神经网络构建轻量化的隐式神经地图,通过点到隐式模型配准方法,实现基于隐式神经地图的激光雷达匹配定位。同时,针对单一激光雷达隐式配准过程中难以应对高速旋转运动的问题,引入 IMU 预积分方法,为隐式配准提供位姿初值,提高配准效率和定位精度。最后,利用因子图融合方法,实现基于隐式神经地图的 LiDAR/IMU 匹配定位。本文设计了大规模高速场景、实测室内走廊及室外校园实验验证算法的定位性能。实验结果表明,本文构建的隐式神经地图内存占用较低,具有轻量化特点;同时,提出的基于隐式神经地图的激光雷达匹配定位算法在定位精度和稳定性上优于传统的地图匹配定位算法,而 IMU 的引入可进一步提高定位精度和实时性。

目前所提的基于隐式神经地图的匹配定位算法,与 ICP 和 NDT 方法一样,需要给定全局初始位姿,故不依赖初始位姿的隐式神经地图全局匹配定位算法值得进一步研究。

参考文献

[1] 周治国,曹江微,邸顺帆. 3D 激光雷达 SLAM 算法综述[J]. 仪器仪表学报,2021,42(9):13-27.
ZHOU ZH G, CAO J W, DI SH F. Overview of 3D LiDAR SLAM algorithms[J]. Chinese Journal of Scientific Instrument, 2021,42(9):13-27.

[2] 吕品,季博文,赖际舟,等. 面向变化场景的 LiDAR 鲁棒定位与地图维护方法[J]. 仪器仪表学报,2022,43(4):291-301.
LYU P, JI B W, LAI J ZH, et al. LiDAR robust positioning and map maintenance method for changing scenes[J]. Chinese Journal of Scientific Instrument, 2022,43(4):291-301.

[3] 余联想,郑明魁,欧文君,等. 多传感器融合的移动机器人室外激光 SLAM 算法优化与系统实现[J]. 电子测量与仪器学报,2023,37(2):48-55.
YU L X, ZHENG M K, OU W J, et al. Optimization and system implementation of outdoor laser SLAM algorithm for mobile robot based on multi sensor fusion[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2):48-55.

[4] 孙伟,曾豪霆,张小瑞,等. 基于点云强度和地面约束的大范围激光 SLAM[J]. 电子测量与仪器学报,2024,38(4):66-75.
SUN W, ZENG H T, ZHANG X R, et al. Large scale based on point cloud strength and ground constraints Lidar SLAM[J]. Journal of Electronic Measurement and Instrumentation, 2024,38(4):66-75.

[5] 李倩,陈付龙,郑亮,等. IMU 紧耦合的多激光雷达定位与建图方法[J]. 电子测量技术,2024,47(9):26-32.
LI Q, CHEN F L, ZHENG L, et al. IMU tightly coupled multi-LiDAR positioning and mapping method[J]. Electronic Measurement Technology, 2024, 47(9):26-32.

[6] YIN H, XU X CH, LU SH, et al. A survey on global LiDAR localization: Challenges, advances and open problems[J]. International Journal of Computer Vision, 2024,132(8):3139-3171.

[7] HESS W, KOHLER D, RAPP H, et al. Real-time loop closure in 2D LiDAR SLAM[C]. IEEE International Conference on Robotics and Automation, 2016:1271-1278.

[8] BESL P J, MCKAY H D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992,14(2):239-256.

[9] GRISETTI G, STACHNISS C, BURGARD W. Improved techniques for grid mapping with rao-blackwellized particle filters[J]. IEEE Transactions on Robotics,

- 2007, 23(1): 34-46.
- [10] 张保, 张安思, 梁国强, 等. 激光雷达室内定位技术研究及应用综述[J]. 激光杂志, 2023, 44(3): 1-9.
ZHANG B, ZHANG AN S, LIANG G Q, et al. Review of LiDAR indoor positioning technology research and application[J]. Laser Journal, 2023, 44(3): 1-9.
- [11] ZHANG J, SINGH S. LOAM: LiDAR odometry and mapping in real-time[C]. Robotics: Science and Systems, 2014, 2(9): 1-9.
- [12] SHAN T X, ENLOT B, MEYERS D, et al. LIO-SAM: Tightly-coupled LiDAR inertial odometry via smoothing and mapping[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 5135-5142.
- [13] XU W, CAI Y X, HE D J, et al. FAST-LIO2: Fast direct LiDAR-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4): 2053-2073.
- [14] 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.
- [15] 余洪山, 付强, 孙健, 等. 面向室内移动机器人的改进 3D-NDT 点云配准算法[J]. 仪器仪表学报, 2019, 40(9): 151-161.
YU H SH, FU Q, SUN J, et al. Improved 3D-NDT point cloud registration algorithm for indoor mobile robot[J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 151-161.
- [16] LI Q, CHEN S, WANG C, et al. LO-Net: Deep real-time LiDAR odometry[C]. 2019 IEEE/CVP Conference on Computer Vision and Pattern Recognition, 2019: 8473-8482.
- [17] WANG G M, WU X R, JIANG SH Y, et al. Efficient 3D deep LiDAR odometry[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(5): 5749-5765.
- [18] ZHOU ZH CH, ZHAO CH, ADOLFSSON D, et al. NDT-transformer: Large-scale 3D point cloud localisation using the normal distribution transform representation[C]. 2021 IEEE International Conference on Robotics and Automation, 2021: 5654-5660.
- [19] TOSI F, ZHANG Y M, GONG Z R, et al. How nerfs and 3D gaussian splatting are reshaping slam: A survey[J]. ArXiv preprint arXiv:2402.13255, 2024.
- [20] 陈久朋, 陈治帆, 伞红军, 等. 基于稠密点云的神经辐射场 NeRF 在视觉 SLAM 建图任务中的应用研究[J]. 仪器仪表学报, 2024, 45(7): 110-120.
CHEN J P, CHEN ZH F, SAN H J, et al. Research on the application of NeRF based on dense point clouds in visual SLAM mapping tasks[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 110-120.
- [21] ZHU S T, WANG G M, BLUM H, et al. SNI-SLAM: Semantic neural implicit SLAM[J]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 21167-21177.
- [22] ZHONG X G, PAN Y, BEHLEY J, et al. SHINE-mapping: Large-scale 3D mapping using sparse Hierarchical implicit neural representations[C]. 2023 IEEE International Conference on Robotics and Automation, 2023: 8371-8377.
- [23] WIESMANN L, GUADAGNINO T, VIZZO I, et al. LocNDF: Neural distance field mapping for robot localization[J]. IEEE Robotics and Automation Letters, 2023, 8(8): 4999-5006.
- [24] DENG J Y, WU Q, CHEN X Y L, et al. NeRF-LOAM: Neural implicit representation for large-scale incremental LiDAR odometry and mapping[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 8218-8227.
- [25] PAN Y, ZHONG X G, WIESMANN L, et al. Pin-slam: LiDAR slam using a point-based implicit neural representation for achieving global map consistency[J]. IEEE Transactions on Robotics, 2024: 4045-4064.
- [26] PARK J J, FLORENCE P, STRAUB J, et al. Deepsdf: Learning continuous signed distance functions for shape representation[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 165-174.
- [27] ZHANG J, KAESSE M, SINGH S. On degeneracy of optimization-based state estimation problems[C]. 2016 IEEE International Conference on Robotics and Automation, 2016: 809-816.
- [28] FORSTER C, CARLONE L, DELLAERT F, et al. On-manifold preintegration for real-time visual-inertial odometry[J]. IEEE Transactions on Robotics, 2016, 33(1): 1-21.
- [29] GIEGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2012: 3354-3361.

作者简介



高旺(通信作者), 2013 年于东南大学获得学士学位, 2018 年于东南大学获得博士学位, 现为东南大学副教授, 主要研究方向为多传感器融合高精度导航定位。

E-mail: gaow@seu.edu.cn.

Gao Wang (Corresponding author) received his B.Sc. degree from Southeast University in 2013, and Ph.D. degree from Southeast University in 2018. Now he is an associate professor at Southeast University. His main research interests include multi-sensors integrated precise navigation and positioning.