

DOI: 10.19650/j.cnki.cjsi.J2514299

顾及几何特征可靠性的 LiDAR 点云配准优化算法 *

孙之寒¹, 高 旺¹, 潘树国¹, 王 强²

(1. 东南大学仪器科学与工程学院 南京 210096; 2. 南京邮电大学自动化学院 南京 210023)

摘要:点云配准是激光雷达(LiDAR)定位的关键技术,为了解决传统点云配准的迭代最近点(ICP)算法在几何特征稀疏及退化场景中面临的挑战,故提出顾及几何特征可靠性的LiDAR点云配准优化方法,该方法包含两个模块:1)基于曲率的特征提取模块,通过构建局部邻域协方差矩阵并分解特征值,计算点云的最大主曲率与最小主曲率,同时引入主曲率差及法向量夹角构建曲率一致性误差函数,通过量化几何特征差异可有效过滤重复结构中易混淆的候选匹配点,解决噪声干扰下的匹配歧义问题,保障特征配准的几何一致性,为后续配准提供高质量特征对;2)基于特征可靠性的点云配准模块,利用特征拟合误差、局部曲率和谱熵这3个因子量化特征拟合质量,通过贝叶斯模型形成统一可靠性权重,基于此权重构建了加权点云配准优化框架,通过权重调节机制抑制低质量特征的干扰,从而降低其对配准结果引入的误差。在自建数据集和公开KITTI数据集上开展了实验验证,结果表明:所提方法在室内特征退化场景的三维定位误差较常规点-线(PL)/点-面(PP)ICP方法降低了47%,显著提升了挑战环境下的定位精度与鲁棒性,并通过消融实验进一步证实了多特征协同优化的重要性,算法在万级特征对规模下优化耗时控制在20 ms以内,满足实时性需求。

关键词: LiDAR; ICP; 鲁棒定位; 点云配准; 几何特征

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

Optimization algorithm for LiDAR point cloud registration considering reliability of geometric features

Sun Zhihan¹, Gao Wang¹, Pan Shuguo¹, Wang Qiang²

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China;
2. School of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Point cloud registration is a key technology for light detection and ranging (LiDAR) positioning. To address the challenges of the traditional iterative closest point (ICP) algorithm in point cloud registration in scenarios with sparse geometric features and degenerated environments, this paper proposes an optimization method for LiDAR point cloud registration considering the reliability of geometric features. This method consists of two modules: 1) A curvature-based feature extraction module that constructs a local neighborhood covariance matrix and decomposes its eigenvalues to calculate the maximum and minimum principal curvatures of the point cloud, while introducing the principal curvature difference and normal vector angle to construct a curvature consistency error function. By quantifying geometric feature differences, it effectively filters out ambiguous candidate matching points in repetitive structures, resolves matching ambiguities under noise interference, ensures the geometric consistency of feature registration, and provides high-quality feature pairs for subsequent registration; 2) A feature reliability-based point cloud registration module that uses three factors—feature fitting error, local curvature, and spectral entropy—to quantify feature fitting quality, forms a unified reliability weight through a Bayesian model, and constructs a weighted point cloud registration optimization framework based on this weight. The weight adjustment mechanism suppresses the interference of low-quality features, thereby reducing the errors introduced into the registration results. Experimental validation on both self-built and public KITTI datasets shows that the proposed method reduces 3D positioning errors by 47% compared to conventional point-line (PL)/point-plane (PP) ICP methods in indoor degraded scenes, significantly improving positioning accuracy.

and robustness in challenging environments. Ablation experiments further confirm the importance of multi-feature collaborative optimization, and the algorithm maintains optimization times within 20 ms for ten thousand-level feature pairs, meeting real-time requirements.

Keywords: LiDAR; ICP; robust localization; point cloud registration; geometric feature

0 引言

近年来,移动机器人和无人平台技术的快速发展,对定位和建图能力提出了更高的要求^[1]。在各类用于定位建图的传感器中,激光雷达(light detection and ranging, LiDAR)因可以提供高分辨率和高精度的三维点云数据而得到广泛应用^[2-3]。在激光雷达定位中,点云配准是其中的核心环节,其是找到一个包括平移和旋转的变换,使得当前帧点云数据与地图点云数据(实时局部地图或全局先验地图)在空间中对齐,从而完成当前帧点云对应位姿的求解。迭代最近点(iterative closest point, ICP)是点云配准常用方法,其通过迭代计算寻找两个点云之间的最近点对应关系,从而完成刚体变换(旋转+平移)求解^[4]。ICP 算法及其衍生算法作为点云配准的经典方法,在结构化环境中具有高效、精确的特性,为激光雷达定位方法奠定了重要基础。

尽管 ICP 算法及其衍生方法被广泛应用,但其性能仍受限于以下两个关键问题:1) 对初始位姿的敏感性;2) 在几何约束不足或几何特征自相似性强的场景下的鲁棒性不足。初始位姿的问题可通过场景识别粗定位、相对定位递推或其它传感器定位解决^[5],但是,对场景的依赖依然是目前制约 ICP 算法应用的关键难题^[6]。

基于点云特征配准方法利用点云集合中的点作为基本元素进行配准^[7]。其中,迭代最近点算法是最经典的方法^[8],最早由 Besl 等^[9]于 1992 年提出。但该算法对点云的初始位置敏感且运行效率低,针对该缺点,ICP 算法的各类改进版本相继出现。最早,Zhang 等^[10]在点到点配准的基础上引入了点对直线的迭代最近点配准(point-to-line ICP, P2L-ICP)算法,对周围环境有了初步的几何特征描述。随后,Bauer 等^[11]引入了点到平面的距离,提出了点对面的迭代最近点(point-to-plane ICP, P2P-ICP)算法,进一步提高了配准效率与鲁棒性。然而,ICP 算法容易陷入局部最优,为了减少误匹配现象^[12],衍生了其他的 ICP 改进算法,引入评价标准来约束或去除错误匹配的对应点,2005 年 Chetverikov 等^[13]利用最小裁剪二乘将重合率作为评判指标来去除距离较小的点对,从而提出截尾迭代最近点(trimmed ICP, TrICP)算法。2009 年 Segal 等^[14]提出了广义迭代最近点(generalized ICP, GICP)算法,将 ICP 算法与概率框架模型结合,通过协方差矩阵调节权重,削减匹配错误的对应点在求解过程中

的影响,增强了算法的鲁棒性和抗噪性。然而,GICP 算法对最近邻搜索步骤的要求较高。因此 Koide 等^[15]提出了体素 GICP(voxelized GICP, VGICP)算法,采用基于体素的关联方法和多重分布的概念,进一步提升了 GICP。2016 年 Yang 等^[16]提出基于分支定界格法的全局最优迭代最近点(globally optimal ICP, Go-ICP)算法,Go-ICP 方法利用八叉树结构划分三维刚性变换空间,推导出配准误差函数的新下界并去除不满足条件的空间。

传统及早期改进 ICP 配准算法通常将所有特征对视为等权贡献,忽略了不同特征在噪声、观测质量及几何约束强度上的差异,这种等权假设在特征质量不均的复杂环境中存在明显不合理性。在点云配准中,特征不确定性主要考虑两个角度:误差的传播与建模。一方面,点云坐标是通过激光束来获得的,当激光束从不同属性的表面反射时,其测量距离的可靠性发生变化,从而导致点云坐标存在不确定性。最初,Behley 等^[17]提出基于面元的建图(surfel-based mapping, SuMa)方法,点云的面元被建模为圆形平面,在地图更新过程中动态更新半径以消除不稳定的面元,其半径大小与测量精度成正比。随后,Jiao 等^[18]研究的多激光雷达外参标定、实时里程计计算与建图(multi-LiDAR extrinsic calibration real-time odometry and mapping, M-LOAM)方法在多 LiDAR 映射中加入了地图不确定性感知,该方法推导了系统内部与外部扰动引起的量测数据不确定性的传播。为研究不确定性随时间的传播规律,Park 等^[19]提出了一种概率面元图融合方法,并使用概率更新方法更新当前匹配的置信度。另一方面,基于点云量测数据的不确定性的研究,对每个点云的坐标及其可靠性之间建立了映射关系,然而在配准过程中一般使用具体的特征(如直线、平面)进行配准,因此需进一步研究特征拟合与配准过程的不确定性。Yuan 等^[20]提出的基于概率自适应的体素映射方法,综合了 LiDAR 测量噪声与位姿估计的不确定性,将两类不确定因素映射到平面参数中,完整地推导了从点到平面特征的不确定性映射。在此基础上,又有较多研究借鉴其对平面不确定性的建模方法,推广到直线特征的不确定性建模中^[21],同时融合了其他定位源^[22],进一步证明了其模型的有效性。

综上,当前的 ICP 及其改进算法虽通过引入点到线、点到面等几何约束提升了配准效率,却普遍忽视特征质量差异对配准精度的影响,导致在特征稀疏或退化场景中性能显著下降。为此,本文提出了顾及几何特征可靠性的 LiDAR 点云配准优化方法:在特征提取层面,通过

对点云曲率一致性筛选,有效解决特征重复结构与噪声干扰下的匹配歧义,提升特征匹配的几何一致性;在点云配准优化层面,引入多维特征质量评估,构建贝叶斯加权优化框架,从而提升配准精度与鲁棒性。

1 基于几何特征可靠性的LiDAR配准算法

1.1 总体框架

如图1所示,本文提出了基于几何特征可靠性的

LiDAR配准质量控制方法系统框架,在利用惯性测量单元(inertial measurement unit, IMU)提供的先验位姿对激光雷达扫描点云进行去畸变、点云去噪、初始对齐等预处理之后,与先验地图一同输入系统,该系统主要包括两个关键模块:1)基于曲率的特征提取模块;2)基于特征可靠性的配准模块。相比于传统的激光雷达ICP配准定位方法,本文提出的方法针对特征提取与特征匹配两个方面分别提出了更加可靠的策略,从而提升了系统定位结果的可靠性。

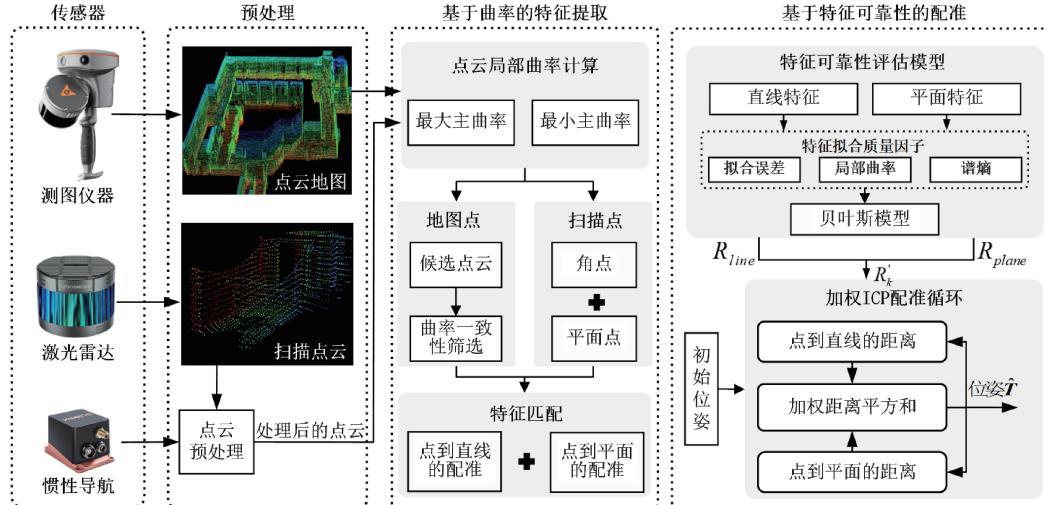


图1 基于几何特征可靠性的LiDAR配准质量控制算法

Fig. 1 Overall framework of LiDAR registration quality control algorithm based on geometric feature reliability

在定位系统中,不同传感器配置与数据预处理是保障后续定位连续性与可靠性的首要环节。一方面,在时间对齐过程中,本系统采用软件时间截校正的方式,可实现毫秒级同步。另一方面,针对运动去畸变问题,本系统采用IMU辅助的连续时间轨迹建模方法。

在基于曲率的特征提取模块中,目标是通过构建点云曲率特征空间,从而实现激光雷达扫描点云与点云地图间高鲁棒性的几何特征匹配。为了实现这个目标,需要对空间搜索提供的候选点云进行筛选,在本模块中引入了扫描点云 p_s 与候选地图点 p_m 之间的曲率一致性误差函数 $\Delta\kappa(p_s, p_m)$ 。由此,本模块形成的点到直线、点到平面两类符合几何一致性的特征匹配,将输入到下一模块进行进一步的优化处理。

在基于特征可靠性的配准模块中,鉴于几何特征的可靠性直接影响位姿估计精度,本模块基于提取到的直线与平面特征,从拟合精度、局部几何特性和方向分布一致性3个维度构建可靠性评估模型,针对三维几何特征拟合质量的评估机制,为各类特征分配差异化权重 R_{line} 与 R_{plane} ,其中 $R \in (0, 1]$ 为每个特征的可靠性提供了定量表征。基于可靠性权重,采用加权优化

策略,使高置信度特征在位姿估计中发挥主导作用,同时抑制低质量特征带来的误差干扰,由此可得到加权优化位姿结果 \hat{T} 。

1.2 基于曲率的特征提取

1) 点云局部曲率

从微分几何的角度来看,三维空间中的曲面在某点处的曲率特性可以通过该点邻域内的二阶近似来描述。如图2所示,对于给定扫描线上的点 p_i ,选取其前后 k 个相邻点构成局部邻域 $N_i = \{p_{i-k}, \dots, p_{i-1}, p_i, p_{i+1}, \dots, p_{i+k}\}$,其中 k 的取值需要权衡计算精度和计算效率,通常取 $k=5$ 。

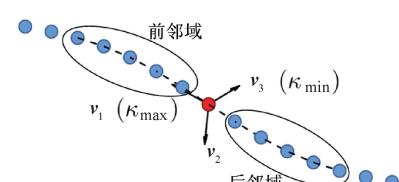


图2 点云局部曲率几何量定义

Fig. 2 Definition of geometric quantities for point cloud local curvature

基于局部邻域 N_i , 通过构造协方差矩阵 Σ_i 来分析点的分布特征, 即:

$$\Sigma_i = \frac{1}{2k+1} \sum_{p_j \in N_i} (p_j - \mu_i)(p_j - \mu_i)^T \quad (1)$$

其中, μ_i 表示邻域 N_i 的质心, 进一步对 Σ_i 进行特征值分解, 得到 3 个特征值 $\lambda_1 > \lambda_2 > \lambda_3$ 及其对应的特征向量 \vec{v}_1 、 \vec{v}_2 和 \vec{v}_3 , 最小特征值对应的特征向量 \vec{v}_3 即为该点对应的法向量 \vec{n}_i 。

基于特征值分解结果, 定义两个关键曲率特征: 最大主曲率 κ_{\max} 和最小主曲率 κ_{\min} , 分别表征了点云局部曲面的最大和最小弯曲程度, 即:

$$\kappa_{\max} = \frac{\lambda_1}{\lambda_1 + \lambda_2 + \lambda_3} \quad (2)$$

$$\kappa_{\min} = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (3)$$

基于上述曲率, 将扫描点云中的点区分为两类: 角点和平面点, 分别用于后续的直线、平面特征拟合。

2) 曲率一致性筛选

在激光雷达点云配准中, 传统基于空间邻近性的特征匹配在特征退化场景中只考虑距离层面的最近邻可能陷入局部最优。为此, 本文提出基于曲率一致性的筛选策略。综合考虑几何特征差异, 可定义曲率一致性误差函数 $\Delta\kappa(p_i, p_j)$, 即:

$$\Delta\kappa(p_i, p_j) = \omega_1 |\kappa_{\max}(p_i) - \kappa_{\max}(p_j)| + \omega_2 |\kappa_{\min}(p_i) - \kappa_{\min}(p_j)| + \omega_3 \angle(\vec{n}_i, \vec{n}_j) \quad (4)$$

其中, $\angle(\vec{n}_i, \vec{n}_j)$ 为法向量夹角, 可通过扫描点 p_i 与地图候选点 p_j 的单位法向量点积计算获得。 ω_1 、 ω_2 、 ω_3 是权重系数, 其选取基于几何特征对匹配歧义的敏感程度与区分能力, 最大主曲率是表征局部几何特征显著性的核心指标, 其差异直接反映特征点在空间弯曲程度上的本质区别, 对重复结构场景下的匹配歧义具有最强的区分能力, 因此赋予最大权重; 最小主曲率主要描述特征点在次要弯曲方向上的特性, 辅助强化特征差异的区分度, 权重次之; 法向量夹角对噪声干扰更敏感, 在特征退化场景中稳定性较弱, 主要用于补充验证几何方向的一致性, 故权重最低。通过实验确定其最优值分别为 0.6、0.3 和 0.1。

对于每个当前扫描特征点 p_i^s , 计算其与所有地图候选点 p_j^m 的曲率一致性误差 $\Delta\kappa(p_i^s, p_j^m)$, 选择误差最小的前 N 个候选点, 通常取 5 个候选点作为最终的特征匹配点。

1.3 基于特征可靠性的配准算法

1) 几何特征拟合质量因子

通常, 三维空间中的一组点云的直线或平面方程各由两个参数定义: 对于直线方程, 需要其方向向量

$\vec{v} = (a_l, b_l, c_l)$ 和一个在直线上的点 $P_{l_0} = (x_{l_0}, y_{l_0}, z_{l_0})$, 对于平面方程, 需要其平面法向量 $\vec{n} = (a_p, b_p, c_p)$ 和一个在平面上的点 $P_{p_0} = (x_{p_0}, y_{p_0}, z_{p_0})$ 。如式(5)和(6)所示, 分别为点云拟合直线与拟合平面的方程, 即:

$$\frac{x - x_{l_0}}{a_l} = \frac{y - y_{l_0}}{b_l} = \frac{z - z_{l_0}}{c_l} \quad (5)$$

$$a_p x + b_p y + c_p z + d = 0 \quad (6)$$

其中, 参数 $d = -(a_p x_{p_0} + b_p y_{p_0} + c_p z_{p_0})$ 。

点云拟合的直线特征与平面特征有 3 个相似特性:

(1) 均为低维空间的线性几何结构, 具有方程显式表达形式; (2) 均具有局部光滑性; (3) 空间分布均具有方向性与一致性。上述 3 个特性决定了模型所选取的 3 个重要的拟合质量因子, 即:

因子 1: 拟合误差。根据点到直线与点到平面的距离公式, 分别得到线特征与面特征的拟合误差, 如式(7)和(8)所示, 分别记为 Q_{l_1} 与 Q_{p_1} 。

$$Q_{l_1} = \frac{1}{N_l} \sum_{i=1}^{N_l} \frac{(P_{l_i} - P_{l_0}) \times \vec{v}}{\vec{v}} \quad (7)$$

$$Q_{p_1} = \frac{1}{N_p} \sum_{j=1}^{N_p} \frac{|\vec{n} P_{p_j} + d|}{\vec{n}} \quad (8)$$

其中, N_l 与 N_p 分别为拟合当前直线与平面的点云数量, P_{l_i} ($i = 1, \dots, N_l$) 与 P_{p_j} ($j = 1, \dots, N_p$) 分别为拟合当前直线与平面的点云坐标, $|\cdot|$ 表示绝对值, $\|\cdot\|$ 表示向量的模值。

因子 2: 局部曲率。局部曲率的大小取决于不符合直线与平面分布的方向所占比重, 这需要计算点云的分布方差, 如式(9)和(10)所示。

$$C_l = \frac{1}{N_l} \sum_{i=1}^{N_l} (P_{l_i} - \mu_l)(P_{l_i} - \mu_l)^T \quad (9)$$

$$C_p = \frac{1}{N_p} \sum_{j=1}^{N_p} (P_{p_j} - \mu_p)(P_{p_j} - \mu_p)^T \quad (10)$$

其中, μ_l 与 μ_p 分别为拟合直线与平面的点云中心点, C_l 与 C_p 分别为拟合直线与平面的点云协方差矩阵。对 C_l 与 C_p 进行特征值分解, 从小到大的特征值: $(\lambda_{l_1}, \lambda_{l_2}, \lambda_{l_3})$ 与 $(\lambda_{p_1}, \lambda_{p_2}, \lambda_{p_3})$ 。由此分别得到线特征与面特征的局部曲率, 如式(11)和(12)所示, 分别记为 Q_{l_2} 与 Q_{p_2} 。

$$Q_{l_2} = \frac{\lambda_{l_1} + \lambda_{l_2}}{\lambda_{l_1} + \lambda_{l_2} + \lambda_{l_3}} \quad (11)$$

$$Q_{p_2} = \frac{\lambda_{p_1}}{\lambda_{p_1} + \lambda_{p_2} + \lambda_{p_3}} \quad (12)$$

因子 3: 谱熵。谱熵的作用在于避免在分布不均匀或方向一致性较差的区域引入较大的拟合误差。与因子 2 类似, 在得到点云的分布特征值后, 归一化后即可得

到直线与平面特征的熵,如式(13)和(14)所示,分别记为 Q_{l_3} 与 Q_{p_3} 。

$$Q_{l_3} = -\sum_{i=1}^3 p_{l_i} \log p_{l_i} \quad (13)$$

$$Q_{p_3} = -\sum_{j=1}^3 p_{p_j} \log p_{p_j} \quad (14)$$

其中, p_{l_i} 与 p_{p_j} 分别为直线与平面各方向的归一化特征值。

2 几何特征可靠性评估模型

上述3个因子分别从不同角度描述了点云的几何特性及其线性拟合质量,为准确评估当前直线特征或平面特征的可靠性,需要构建一个统一的可靠性评估模型。根据贝叶斯理论,可靠性可以理解为在给定3个拟合质量因子的条件下,当前模型为“可靠事件”的后验概率:

$$P(\text{Reliable} | Q_1, Q_2, Q_3) = P(Q_1, Q_2, Q_3 | \text{Reliable}) \cdot \frac{P(\text{Reliable})}{P(Q_1, Q_2, Q_3)} \quad (15)$$

其中, $P(\text{Reliable} | Q_1, Q_2, Q_3)$ 为后验概率,即在给定点云拟合质量 Q_1, Q_2, Q_3 的条件下,当前直线或平面特征可靠的概率。 $P(Q_1, Q_2, Q_3 | \text{Reliable})$ 为似然函数,表示在当前直线或平面特征可靠时,点云拟合质量为 Q_1, Q_2, Q_3 的概率。

上述3类因子中,拟合误差主要反映LiDAR的测量噪声,包括测距噪声与姿态估计误差,其误差来源与传感器硬件特性及位姿解算精度直接相关;局部曲率由物体自身的几何结构决定,取决于环境中物理表面的弯曲程度,与测量过程中的噪声无关;熵则表征点云在空间中的分布均匀性与方向一致性,反映场景结构的统计特性,其变化规律独立于测量噪声和物体固有曲率。三者从不同层面表达了点云几何特征的拟合质量对配准的误差的影响,因此在数据处理时,为便于计算可认为三者相互独立。此时式(15)可简化为:

$$P(Q_1, Q_2, Q_3 | \text{Reliable}) = P(Q_1 | \text{Reliable}) \cdot P(Q_2 | \text{Reliable}) \cdot P(Q_3 | \text{Reliable}) \quad (16)$$

考虑到拟合误差、局部曲率、熵的概率密度函数在特征可靠条件下近似为高斯分布,其概率值随因子增大而快速衰减,因此可认为每个特征在可靠性条件下的概率服从指数分布,指数分布常用于描述“越小越好”的随机变量,这与 Q_1, Q_2, Q_3 变量相符合,由于特征可靠性是相对量,忽略先验概率与证据项后,后验概率可化简为:

$$P(\text{Reliable} | Q_1, Q_2, Q_3) \propto e^{-Q_1} \cdot e^{-Q_2} \cdot e^{-Q_3} \quad (17)$$

因此,直线或平面特征的综合可靠性 R_{line} 与 R_{plane} 分别为:

$$R_{line} = e^{-Q_{l_1}} \cdot e^{-Q_{l_2}} \cdot e^{-Q_{l_3}} \quad (18)$$

$$R_{plane} = e^{-Q_{p_1}} \cdot e^{-Q_{p_2}} \cdot e^{-Q_{p_3}} \quad (19)$$

上述综合可靠性模型表明,当 $Q_1, Q_2, Q_3 \in [0, +\infty)$ 时, $R \in (0, 1]$,且 R 的值与 Q_1, Q_2, Q_3 这3个因子均呈负相关,其中每个因子独立地对特征可靠性产生影响;拟合误差的减小、局部曲率的减小、熵的减小均会使得几何特征的可靠性提升,它们分别从测量噪声、固有几何属性、分布特性3个独立维度影响可靠性,同时这种关系与实际几何意义相符。

3 加权优化点云配准

基于特征可靠性模型,直线特征与平面特征的可靠性的值 R_{line} 与 R_{plane} 将输入加权优化模块,简记为 R_{l_i} ($i = 1, \dots, N_l$)与 R_{p_j} ($j = 1, \dots, N_p$)。由于在后续的优化中,点到直线和平面的距离将统一纳入优化目标函数,设直线特征集合对应的可靠性权重为 R_{l_k} ($k = 1, \dots, N_l$),平面特征集合对应的可靠性权重为 R_{p_k} ($k = 1, \dots, N_p$),定义合并后的全局可靠性权重向量为 \mathbf{R}'_k ($k = 1, \dots, N_l + N_p$),其映射关系为:

$$\mathbf{R}'_k = \begin{cases} \mathbf{R}_{l_k}, & 1 \leq k \leq N_l \\ \mathbf{R}_{p_{k-N_l}}, & N_l < k \leq N_l + N_p \end{cases} \quad (20)$$

对于给定源点云 $P = \{P_k\}$,($k = 1, \dots, N$),以及其对应提取的局部地图中的各个特征 $Q = \{Line_i, Plane_j\}$,($i = 1, \dots, N_l$, $j = 1, \dots, N_p$),需要分别计算 P 到 Q 的距离,即:

$$d_{line}(R, t, P_k, Q_{k_0}, \vec{v}_k) = \frac{(RP_k + t - Q_{k_0}) \times \vec{v}_k}{|\vec{v}_k|} \quad (21)$$

$$d_{plane}(R, t, P_k, Q_{k_0}, \vec{n}_k) = \frac{|(RP_k + t - Q_{k_0}) \vec{n}_k|}{|\vec{n}_k|} \quad (22)$$

其中,位姿 $(R, t) \in SE(3)$ 表示由激光雷达系到世界坐标系的变换, Q_{k_0} 表示特征直线或者平面上的一点, \vec{v}_k 与 \vec{n}_k 分别表示直线的方向向量与平面的法向量,为了将点到直线与平面的距离统一纳入优化目标函数,可定义统一的距离函数,即:

$$d_k(R, t) = \begin{cases} d_{line}(R, t, P_k, Q_{k_0}, \vec{v}_k), & P_k \text{ 为角点} \\ d_{plane}(R, t, P_k, Q_{k_0}, \vec{n}_k), & P_k \text{ 为平面点} \end{cases} \quad (23)$$

由此可得,加权ICP的优化目标函数,即:

$$E(R, t) = \sum_{k=1}^N R'_k \cdot d_k^2(R, t) \quad (24)$$

上述目标函数经最小二乘法求解,即可得到当前帧的位姿估计 $\hat{T} = (\hat{R}, \hat{t})$ 。

2 实验验证与分析

2.1 自测数据集验证

为验证本文方法在实际场景中的性能,本文搭建了测试平台,其硬件配置与传感器安装方式如图3所示。

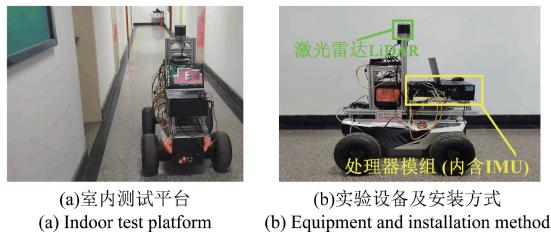


图 3 自建数据集的室内测试平台与设备安装

Fig. 3 Indoor test platform and equipment installation of self-built dataset

实验选用松灵 HUNTER 阿克曼底盘四轮无人车, Velodyne VLP-32 激光雷达与工业级六轴 IMU。由华测 RS10 高精度实时动态差分 (real-time kinematic, RTK) 导航设备提供先验点云地图, 采用室内外连续建图方法: 在室外系统基于 RTK-LiDAR 融合的同时定位与建图 (simultaneous localization and mapping, SLAM) 构建大尺度地图; 在室内通过全站仪标定控制点建立高精度坐标框架。无人车的参考轨迹基于测绘级高精度点云地图的点到点配准, 经后处理优化生成。系统主控制器采用 NVIDIA Jetson AGX Orin, Ubuntu 20.04 操作系统。

实验场景选择室内走廊的一条闭环路线, 如图 4 所示, 本文对室内测试场景进行了分段和标注, 涵盖多种空间形态。

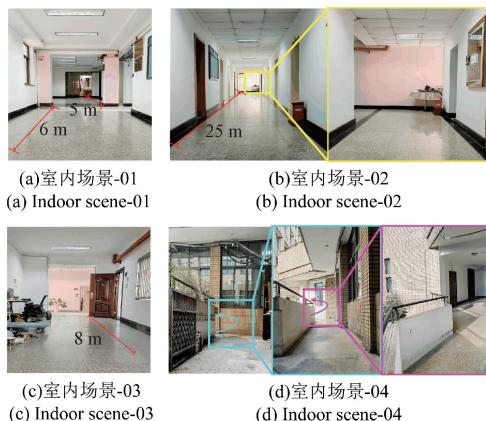


图 4 室内测试场景与划分

Fig. 4 Indoor test scenes and their division

如表 1 所示, 本文自建数据集覆盖多样化室内场景, 场景在轨迹长度、持续时间及空间形态上各有差异。在空间几何特征不同的数据集上开展实验, 可验证本文方法在复杂室内环境的适用性。

为便于描述, 将本文所提的顾及几何特征可靠性的迭代最近点 (geometric feature reliability ICP, GFR-ICP) 算法简称为 GFR-ICP 算法, 同时设计了两种 GFR-ICP 消融算法: 1) GFR-W/O-P 算法仅对直线特征进行可靠

表 1 本文自建数据集说明

Table 1 Description of the self-built dataset in this paper

场景	轨迹长度/m	持续时间/s	代表性场景
01	13.74	53.00	短距离走廊
02	25.11	48.00	长距离狭窄走廊
03	14.10	38.00	四周含门窗的走廊
04	37.22	73.00	带拐角的蜿蜒走廊

性评估与加权优化, 而平面特征进行等权优化; 2) GFR-W/O-L 算法仅对平面特征进行可靠性评估与加权优化, 而直线特征进行等权优化。在后文实验中, 使用融合先验地图模块的常规点-线 (PL)/点-面 (PP) 的 PL-PP-ICP 方法与本文算法进行对比。

如表 2 所示, 列出了不同场景序列的定位结果, 其中最优结果以粗体表示, 次优结果以下划线表示, 本文 GFR-ICP 算法在三维定位误差均为最优, 其全程平均三维误差为 0.17 m, 较 PL-PP-ICP 算法的三维定位误差降低 47%。本文 GFR-ICP 算法的三维定位精度显著优于 PL-PP-ICP 算法; 消融平面特征 GFR-W/O-P 算法的性能虽然与 PL-PP-ICP 的精度基本持平, 但是在一些空间环境突变的地方能够抑制定位误差的突增, 例如, 当墙面几何连续性突然中断时线特征质量因子的约束机制抑制了低质量特征的错误依赖; GFR-W/O-L 的误差值基本接近 GFR-ICP 算法, 说明平面特征对算法精度的提升起主导作用。

表 2 室内场景下的定位误差 RMSE 在水平与三维方向上的比较

Table 2 Comparison of positioning errors RMSE in horizontal and 3D directions under indoor scenes

场景序列	PL-PP-ICP	GFR-W/O-P	GFR-W/O-L	GFR-ICP-ICP (本文算法)
	水平三维	水平三维	水平三维	水平三维
01	0.13	0.12	<u>0.07</u>	0.05
	0.20	0.17	<u>0.12</u>	0.09
02	0.19	0.14	<u>0.09</u>	0.07
	0.31	0.24	<u>0.17</u>	0.14
03	0.20	0.15	<u>0.10</u>	0.08
	0.28	0.25	<u>0.15</u>	0.13
04	0.30	0.28	<u>0.17</u>	0.14
	0.41	0.37	<u>0.25</u>	0.24
平均	0.22	0.19	<u>0.13</u>	0.11
	0.32	0.28	<u>0.18</u>	0.17

如图5所示,通过全局轨迹与局部细节验证了算法的稳定性,图5(a)标注的(b)、(c)、(d)、(e)分别为场景序列01、02、03、04对应的典型区域,整体而言PL-PP-ICP算法的定位轨迹在运动状态发生变化以及环境空间突变的时刻,常出现异常跳变,而GFR-ICP算法的轨迹对这种变化的鲁棒性较高,全程的定位轨迹较为平滑。在走廊分岔区域(室内场景-01),GFR-ICP轨迹与真值贴合度显著优于PL-PP-ICP算法,最大偏移量控制在0.1 m内。在连续拐弯走廊处(室内场景-04),本文GFR-ICP算法有效抑制了因载体运动快使得ICP算法陷入局部最优的现象。

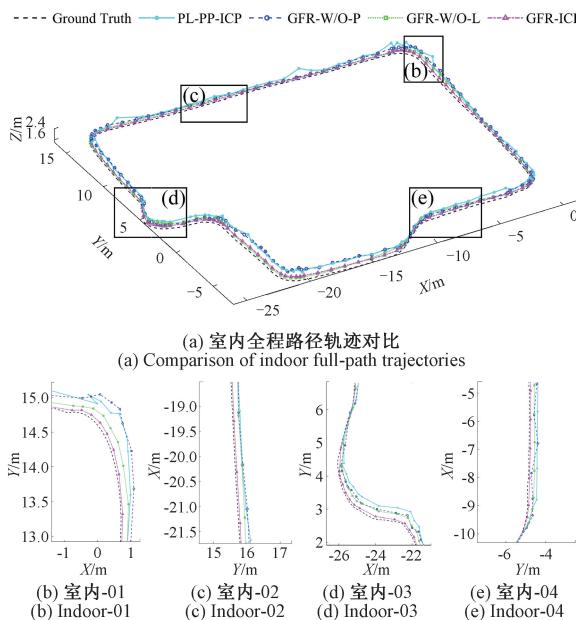


图5 室内场景定位轨迹对比

Fig. 5 Comparison of positioning trajectories in indoor scenes

2.2 公开数据集验证

为验证算法普适性,本文研究在KITTI公开数据集开展实验验证。该数据集采集于室外真实车辆驾驶场景,以轿车为采集平台,配备Velodyne HDL-64E激光雷达(10 Hz)和RTK/INS组合导航(IMU为10 Hz),可提供精确的时空同步与真值参考数据。

定位误差统计如表4所示,其中最优结果以粗体表示,次优结果以下划线表示,在存在动态障碍物且特征多样的城市道路场景中,GFR-ICP方法通过动态几何可靠性评估,在各个数据集中较PL-PP-ICP算法均有所降低。

定位误差统计如表4所示,其中最优结果以粗体表示,次优结果以下划线表示,在存在动态障碍物且特征多样的城市道路场景中,GFR-ICP方法通过动态几何可靠性评估,在各个数据集中较PL-PP-ICP算法均有所降低。

表3 本文所选KITTI各数据集说明

Table 3 Description of KITTI datasets selected in this paper

数据集	轨迹长度/m	持续时间/s	代表性场景
00	3 626.60	457.50	城市主干道与交叉路口
05	2 203.30	287.40	多弯道的城市次干道
07	692.90	112.60	绿化带分隔的双向车道
09	1 702.60	165.00	开阔区域与密集建筑群过渡场景

表4 KITTI数据集的定位误差RMSE在水平与三维方向上的比较

Table 4 Comparison of positioning errors RMSE in horizontal and 3D directions for KITTI datasets

场景 序列	(m)			
	PL-PP-ICP 水平三维	GFR-W/O-P 水平三维	GFR-W/O-L 水平三维	GFR-ICP (本文算法) 水平三维
00	0.56	0.25	<u>0.15</u>	0.13
	1.01	0.61	<u>0.33</u>	0.27
05	0.32	0.29	<u>0.19</u>	0.17
	0.39	0.35	<u>0.26</u>	0.20
07	0.25	0.23	<u>0.14</u>	0.14
	0.33	0.28	<u>0.19</u>	0.16
09	0.15	0.12	<u>0.09</u>	0.07
	0.23	0.17	<u>0.13</u>	0.11

如图6所示,通过定位轨迹的对比验证了本文算法在室外场景的稳定性,整体而言,PL-PP-ICP算法定位轨迹在场景特征变化时易出现异常跳变,而GFR-ICP算法轨迹更平滑且与真值贴合度高。从实验结果来看,基于特征可靠性的优化能够强化优质特征的约束,抑制低质量特征的干扰,从而提升定位系统整体的稳定性。

2.3 消融实验

为系统评估多特征协同优化机制的有效性,本研究设计了消融实验对比。

如图7和8所示的特征消融误差累计曲线形态的对比,本质上也映射了不同算法对特征约束的利用差异:单一特征消融算法呈现的从起初滞后到逐渐平缓型的累积分布函数(cumulative distribution function,CDF),反映其场景适应能力存在边界;完整的GFR-ICP算法的从快速增长平稳型分布,体现多特征弹性耦合的动态平衡。这种平衡源于两类特征拟合质量评估因子的调节作用,在约束冗余场景抑制低质量特征约束,在特征稀疏场景强化特征互补,最终实现定位误差的稳定控制。

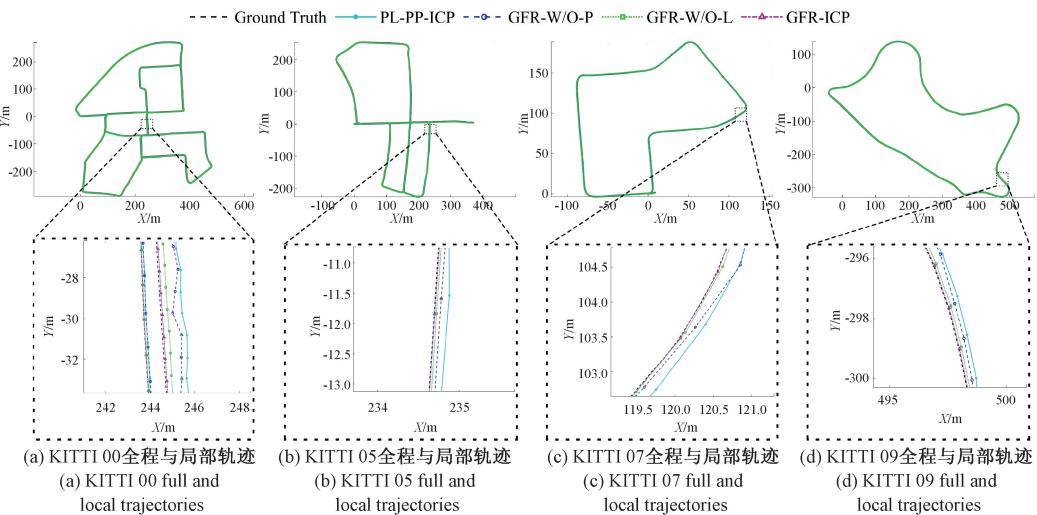


图 6 KITTI 各数据集定位轨迹对比

Fig. 6 Comparison of localization trajectories on various KITTI datasets

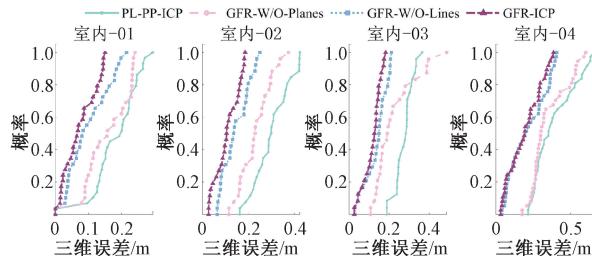


图 7 室内场景各序列的三维位置误差 CDF 对比

Fig. 7 Comparison of CDFs for 3D position errors across sequences in indoor scenes

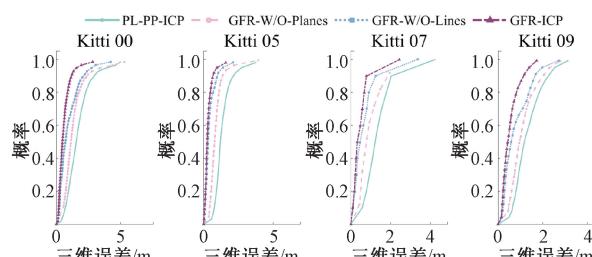


图 8 KITTI 各数据集的三维位置误差 CDF 对比

Fig. 8 Comparison of CDFs for 3D position errors across datasets in KITTI

基于 Intel i7-9750H 平台的实测数据, 图 9 的算法耗时分析验证了特征可靠性评估模块的实时可行性。尽管平面特征的可靠性计算耗时高于线特征可靠性的计算, 然而完整 GFR-ICP 算法在 10 000 特征对规模下的优化最大耗时可控制在 20 ms 以内。

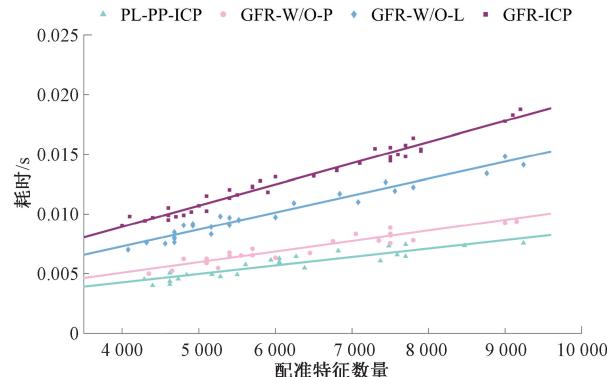


图 9 各算法在不同特征对数量下的耗时对比

Fig. 9 Comparison of time consumption for various algorithms under different numbers of feature pairs

3 结 论

本文提出了基于几何特征可靠性的 LiDAR 配准质量控制方法, 主要贡献为: 首先, 提出了一种基于曲率一致性的特征提取方法, 通过最大主曲率差、最小主曲率差和法向量夹角这 3 个几何特征构建误差函数, 有效解决了重复几何结构和噪声干扰下的特征匹配问题。其次, 设计了特征可靠性评估模型, 从拟合误差、局部曲率和谱熵这 3 个维度综合评估几何特征的拟合质量, 为不同可靠性的特征分配差异化权重。最后, 推导了基于特征加权优化的配准方法, 将特征可靠性融入 ICP 配准过程, 抑制低质量特征引入的误差, 同时提供位姿估计的协方差分析。实验结果表明, 本研究的质量控制方法, 在室内外多样化场景中均表现出优越

性能。消融实验进一步验证了多特征协同优化的重要性,尤其是在几何约束维度丰富的场景中,线面特征的互补效应显著提升了系统鲁棒性。本文提出的基于几何特征可靠性的配准质量控制方法不仅适用于激光雷达点云配准,其核心思想也可推广到其他基于几何特征的定位与建图系统中。

目前提出的配准质量控制方法的有效性依赖粗配准提供的初始位姿精度,在初始误差较大时可能出现收敛问题,研究更加鲁棒的初始位姿估计方法将成为未来工作的重点研究方向。

参考文献

- [1] 邓锐添,辜晓波,邱泽扬,等.复杂环境下无人系统自主定位与测速[J].导航定位学报,2025,13(1):119-127.
- [2] GAO W, ZHAO H, LIU H, et al. LiDAR/IMU matching localization algorithm based on implicit neural map[J]. Chinese Journal of Scientific Instrument, 2024, 45(12): 74-84.
- [3] 孙明晓,王鑫源,栾添添,等.动态环境下基于深度图的无人车激光SLAM算法[J].仪器仪表学报,2025,46(3): 101-109.
- [4] 李艳红,闫建国,王晓燕.基于邻域曲率改进的迭代最近点激光雷达目标点云配准[J].激光与光电子学进展,2023,60(2): 396-401.
- [5] 钟雷声,夏辉,陈佳林.基于双目视觉和单线激光雷达的三维场景重建系统和算法[J].测绘通报,2024(5): 48-52,59.
- [6] SUN W, ZENG H T, ZHANG X R, et al. Large-scale laser SLAM based on point cloud intensity and ground constraints[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 66-75.
- [7] 冯田,冯志辉,南亚明,等.基于特征向量提取的点云配准算法[J].电子测量技术,2022,45(15): 57-62.
- [8] CHEN X, ZHANG D B, ZHANG J F, et al. High-precision and efficient registration method for point clouds with complex features[J]. Modern Electronics Technique, 2025, 48(4): 181-186.
- [9] BESL P J, MCKAY N D. Method for registration of 3-D shapes[C]. Sensor Fusion IV: Control Paradigms and Data Structures, Spie, 1992, 1611: 586-606.
- [10] ZHANG ZH Y. Iterative point matching for registration of free-form curves and surfaces[J]. International Journal of Computer Vision, 1994, 13(2): 119-152.
- [11] BAUER D, PATTER T, VINCZE M. SporeAgent: Reinforced scene-level plausibility for object pose refinement[C]. 2022 IEEE/CVF Winter Conference on Applications of Computer Vision, 2022: 654-662.
- [12] 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.
- [13] LI Q, CHEN F L, ZHENG L, et al. Multi-LiDAR localization and mapping method with tightly coupled IMU[J]. Electronic Measurement Technology, 2024, 47(9): 26-32.
- [14] CHETVERIKOV D, STEPANOV D, KRSEK P. Robust Euclidean alignment of 3D point sets: The trimmed iterative closest point algorithm[J]. Image and Vision Computing, 2024, 135: 104-114.

- Computing, 2005, 23(3): 299-309.
- [14] SEGAL A, HAEHNEL D, THRUN S. Generalized-ICP[C]. Robotics: Science and Systems, 2009, 2(4): 435.
- [15] KOIDE K, YOKOZUKA M, OISHI S, et al. Voxelized GICP for fast and accurate 3D point cloud registration[C]. 2021 IEEE International Conference on Robotics and Automation, 2021: 11054-11059.
- [16] YANG J L, LI H D, CAMPBELL D, et al. Go-ICP: A globally optimal solution to 3D ICP point-set registration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(11): 2241-2254.
- [17] BEHLEY J, STACHNISS C. Efficient surfel-based SLAM using 3D laser range data in urban environments[C]. Robotics: Science and Systems, 2018, 2018: 59.
- [18] JIAO J H, YE H Y, ZHU Y L, et al. Robust odometry and mapping for multi-lidar systems with online extrinsic calibration[J]. IEEE Transactions on Robotics, 2021, 38(1): 351-371.
- [19] PARK C, KIM S, MOGHADAM P, et al. Probabilistic surfel fusion for dense LiDAR mapping[C]. 2017 IEEE International Conference on Computer Vision Workshops, 2017: 2418-2426.
- [20] YUAN CH J, XU W, LIU X Y, et al. Efficient and probabilistic adaptive voxel mapping for accurate online LiDAR odometry[J]. IEEE Robotics and Automation Letters, 2022, 7(3): 8518-8525.
- [21] ZHU F, XIAO T Y, XU ZH, et al. Uncertainty modeling for plane and line features to improve consistency in RTK/INS/LiDAR integrated navigation[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 21002-21020.

- [22] LIU H, PAN SH G, WU P B, et al. Uncertainty-aware UWB/LiDAR/INS tightly coupled fusion pose estimation via filtering approach[J]. IEEE Sensors Journal, 2024, 24(7): 11113-11126.

作者简介



孙之寒, 2024 年于东南大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为多源融合定位及其质量控制方法。

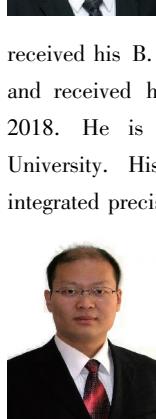
E-mail: zhihan_sun@seu.edu.cn



Sun Zhihan received her B. Sc. degree from Southeast University in 2024 and she is currently a master's student at Southeast University. Her main research interest includes multi-source fusion positioning and its quality control methods.

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 received his Ph. D. degree from Southeast University in 2018. He is currently an associate professor at Southeast University. His main research interest includes multi-sensors integrated precise navigation and positioning.

王强, 2009 年于南京航空航天大学测试计量技术及仪器专业获得博士学位, 现为南京邮电大学教授, 主要研究方向为智能测控技术。

E-mail: wangqiang@njupt.edu.cn

Wang Qiang received his Ph. D. degree in the major of Measurement and Testing Technology and Instruments from Nanjing University of Aeronautics and Astronautics in 2009. He is currently a professor at Nanjing University of Posts and Telecommunications. His main research interest includes intelligent measurement and control technology.