DOI：10.20189/j.cnki.CN/61-1527/E.202506012

基于自适应共识随机采样一致性的多传感器融合定位方法

徐洁阳，刘洁瑜*，汪立新，李　灿，陈艺豪
（火箭军工程大学，西安 710025）

摘　要：为解决LiDAR/IMU里程计在车辆长距离自主导航过程中累积误差持续增长的问题，提出一种基于自适应共识随机采样一致性（consensus-adaptive random sample consensus，CA-RANSAC）的LiDAR/IMU/GPS多传感器融合定位方法。该方法采用三模块设计，前端融合模块使用变分贝叶斯优化的单次迭代不变扩展卡尔曼滤波器（variational Bayesian-based single-iteration invariant extended Kalman filter，VB-SIEKF）来实现LiDAR和IMU数据的高精度融合，为后端优化提供里程计约束因子；中端回环检测模块构建了基于圆柱形区域分割的高效点云描述符，并通过主成分分析法对其进行降维处理，结合CA-RANSAC的自适应阈值调整机制显著提升了回环检测的成功率；后端优化模块建立了集成GPS因子、IMU预积分因子、回环检测因子和LiDAR/IMU里程计因子的全局因子图优化模型，通过非线性优化求解全局一致的位姿序列。在KITTI数据集中3个典型场景下的对比实验结果表明：所提方法在3个场景中的均方根位置误差相较于单一使用VB-SIEKF的LiDAR/IMU里程计方法分别降低了66.8%、67.5%和66.2%，相较于传统RANSAC融合方法分别降低了49.4%、50.6%和52.1%，且回环检测成功率高达86.7%以上，误匹配率控制在9.2%以内，充分证明了所提方法具有较强的实用性。

关键词：融合定位；因子图优化；回环检测；随机采样一致性
中图分类号：TN958.98　　**文献标志码：**A　　**文章编号：**2097-2741(2025)06-0124-13

Consensus-Adaptive Random Sample Consensus-Based Multi-Sensor Fusion Localization Method

XU Jieyang，LIU Jieyu*，WANG Lixin，LI Can，CHEN Yihao
（Rocket Force University of Engineering，Xi'an 710025，China）

ABSTRACT: To address the critical issue of cumulative error growth in LiDAR/IMU odometry during long-distance autonomous navigation，a LiDAR/IMU/GPS multi-sensor fusion localiza-

收稿日期：2025-06-26　　**修回日期**：2025-08-01　　**录用日期**：2025-08-18
基金项目：陕西省自然科学基金（2024JC-YBQN-674）
第一作者：徐洁阳（2001—），女，硕士研究生，主要从事导航制导与仿真研究。E-mail：xujieyang07@163.com
*__通信作者__：刘洁瑜（1970—），女，教授，主要从事惯性导航研究。E-mail：liujieyu128@163.com

引用格式：徐洁阳，刘洁瑜，汪立新，等.基于自适应共识随机采样一致性的多传感器融合定位方法[J].火箭军工程大学学报，2025，39（6）：124-136. *XU Jieyang，LIU Jieyu，WANG Lixin，et al. Consensus-adaptive random sample consensus-based multi-sensor fusion localization method[J]. Journal of Rocket Force University of Engineering，2025，39（6）：124-136.*

tion method based on consensus-adaptive random sample consensus（CA-RANSAC） was proposed. The proposed method adopted a three-module framework. The front-end fusion module employed a variational Bayesian-based single-iteration invariant extended Kalman filter（VB-SIEKF）to achieve high-precision fusion of LiDAR and IMU data, providing odometry constraint factors for back-end optimization. An intermediate loop detection module constructed an efficient point cloud descriptor through cylindrical region segmentation, and applied principal component analysis for dimensionality reduction. The adaptive threshold adjustment mechanism of CA-RANSAC significantly enhanced the accuracy and robustness of the loop closure detection. A back-end optimization module established a global factor graph optimization model that integrated GPS factors, IMU preintegration factors, loop closure detection factors, and LiDAR / IMU odometry factors, solving a globally consistent pose sequence through nonlinear optimization. Extensive comparative experiments on multiple representative scenarios from the KITTI dataset demonstrate that, compared with the LiDAR/IMU odometry method using only VB-SIEKF and traditional RANSAC-based fusion method,the proposed method reduces the root mean square error of position by 66.8%、67.5%、66.2% and 49.4%、50.6%、52.1%, respectively,in three scenarios. The loop closure detection success rate exceeds 86.7%, and the mismatch rate is maintained within 9.2%, fully validating the practicality of the proposed method.

KEYWORDS: fusion localization；factor graph optimization；loop closure detection；random sample consensus

随着自动驾驶技术的快速发展，使用激光雷达（light detection and ranging，LiDAR）和惯性测量单元（inertial measurement unit，IMU）构成的LiDAR/IMU里程计方法得到了广泛推广和应用[1]。通过卡尔曼滤波融合LiDAR和IMU的测量结果，可以使车辆在复杂环境或高动态场景下进行准确定位。但随着行驶距离的增加，里程计的累积误差将会逐渐增大，从而带来定位结果的偏差[2]。为应对这一关键挑战，研究人员开始探索引入全球卫星导航系统（global navigation satellite system，GNSS）作为外部参考[3-4]，并结合优化的回环检测算法[5]来进一步提升目标定位准确性。尤其是在城市固定路线的重复行驶和长距离高速公路行驶过程中，研究回环检测问题对无人车的高精度定位具有重要意义。本文重点解决传统回环检测过程中存在的误匹配问题，以提高其在复杂环境应用中的可靠性。近年来，回环检测技术主要包括基于位置统计、地图匹配、特征描述和深度学习的回环检测方法。

基于位置统计的回环检测方法计算效率高，但对环境变化较为敏感。例如：Hu等[6]通过对移动机器人的地面运动施加合理约束，同时考虑初始定位误差对导航的影响，设计关键帧选择策略，有效提升了定位的平稳性、准确性及回环检测效率；张博等[7]针对惯性偏差漂移的问题，引入二维码约束信息并结合因子图来实现多层次的数据融合，以提高定位精度与鲁棒性。尽管基于位置的回环检测效率较高，但面对光照变化或特征缺失等情况时仍容易产生误判。

基于地图匹配的回环检测方法精度高、鲁棒性强，但点云配准计算量大、实时性较差[8]。为缓解其对计算资源的高需求，高旺等[9]构建轻量化神经地图以提升计算效率，显著提高了地图匹配的实时性。Shi等[10]采用占据位置描述符来加速场景匹配，并提出一种高效的地图辅助场景识别与定位方法。然而，该类方法对地图完整度依赖性强，在稀疏或退化环境下易受影响。

基于特征描述的回环检测方法通过提取环境中的显著特征来提高匹配准确性[11]，但过多特征提取会牺牲回环检测的实时性[12]。为兼顾计算效率和鲁棒性，Liu等[13]借助距离图像与广度优先搜索算法来提升回环检测效率；毛清华等[14]融合LiDAR与IMU的数据来实现煤矿掘进巷道的三维重建并实现回环帧的全局位姿矫正；在此基础上，为增强回环检测判别力与稳定性，李飞翔等[15]提出时空描述符，Zhang等[16]设计了一种投影上下文描述符，均能在复杂场景下获得更稳定的检测结果，但高维描述符带来的计算负担仍制约着算法

的实时性。此外，为提升回环检测的有效性，Zhang等[17]提出一种新型强度圆柱投影形状上下文描述符以及相似度估计方法，显著提升在环境特征稀疏场景中的定位精度；基于迭代扩展卡尔曼滤波（iterative extended Kalman filter，IEKF）[18]，Pan[19]等提出一种里程计算方法，能够显著提升初始位姿精度，同时考虑几何信息和强度信息构造了新的全局描述符，以弥补原始点云描述符在回环检测精度上的不足。

基于深度学习的回环检测方法通过神经网络获取和学习强判别特征，算法精度高且鲁棒性较好，但依赖于大规模标注数据集来对模型进行训练，耗时较长，且数据获取与标注成本高[20]。为兼顾检测效率与计算成本，Xiang等[21]提出一种基于综合描述符与机器学习的快速回环检测方法，并采用双层回环候选验证策略剔除错误结果，从而显著提高算法的匹配精度和检测效率。

尽管现有研究方法均从不同角度改进并提升了回环检测效率及其鲁棒性，但LiDAR/IMU/GPS融合系统仍面临以下3点核心技术挑战：一是传统点云描述方法难以兼顾特征表达能力和计算效率，在复杂环境中的匹配误差率高，实时性能不佳；二是传统回环检测算法多采用固定阈值进行特征匹配，无法根据场景特征进行动态调整；三是缺乏有效的全局约束机制来减小LiDAR/IMU里程计在长距离运行过程中的累积误差，致使导航系统的定位精度逐渐下降。

鉴于此，本文提出一种基于自适应共识随机采样一致性（consensus-adaptive random sample consensus，CA-RANSAC）算法[22]的LiDAR/IMU/GPS融合定位方法，从特征表达、匹配算法和多传感器融合框架3个层面来提升无人车定位系统的性能。针对传统点云描述符存在的弊端，通过构建高效点云描述符结合主成分分析法（principal component analysis，PCA）降维处理，从而实现特征表达能力与计算效率的提升；针对传统RANSAC使用固定阈值易产生误匹配的问题，通过引入共识度评估机制和自适应阈值调整策略，使系统能够根据环境特性来动态优化特征匹配过程；为解决LiDAR/IMU里程计的长距离累积误差，本文采用多传感器融合因子图优化框架，将多源传感器数据形式化为概率图模型中的约束因子，并通过非线性优化方法求解全局一致的状态估计。

1 问题描述与框架设计

1.1 问题描述

针对无人车长距离自主导航的高精度定位需求，本文面向无人车融合定位系统设计，在速度范围为0～120 km/h的复杂运动模式下，重点关注以下2类典型应用场景。

1）长距离高速公路场景。车辆在高速公路长距离行驶过程中，虽然GPS信号相对稳定，但里程计长时间运行会产生漂移误差，需要算法在数十公里行驶距离内具备有效的累积误差修正机制。

2）结构化环境重复路径场景。在停车场、园区道路等结构化环境中，无人车经常需要在相同或相似的路径上重复行驶。这类场景为回环检测提供了良好的应用条件，但对算法的重定位精度和实时性要求更高。

1.2 整体框架设计

针对LiDAR/IMU/GPS融合定位系统面临的3个核心技术挑战，本文提出基于CA-RANSAC的LiDAR/IMU/GPS融合定位算法，采用前端融合-中端检测-后端优化的三模块架构，整体框架如图1所示。其中，前端融合模块负责实时处理高频传感器数据，生成短时间内高精度的相对位姿估计，为后端优化提供里程计约束因子；中端回环检测模块通过识别历史访问位置，构建长距离的全局约束因子，有效抑制累积误差的增长；后端优化模块统一处理多源约束信息，通过非线性优化求解全局一致的位姿序列。3个模块在时间维度上并行工作，在空间维度上相互补充，共同构成了一个完整的多传感器融合定位算法。

2 LiDAR/IMU里程计因子

2.1 前端LiDAR/IMU数据融合

前端LiDAR/IMU融合模块采用变分贝叶斯优化[23]的单次迭代不变扩展卡尔曼滤波（variational Bayesian-based single-iteration invariant extended Kalman filter，VB-SIEKF）算法，将IMU的高频角速度和加速度测量值与LiDAR的低频高精度空间感知信息进行时空同步融合，输出的相对位姿变换将作为里程计因子输入到后端因子图优化模块，为系统提供连续的运动约束，是整个定位系统的数据预处理单元。不同于传统卡尔曼滤波需要预先设定固定噪声参数，VB-SIEKF能

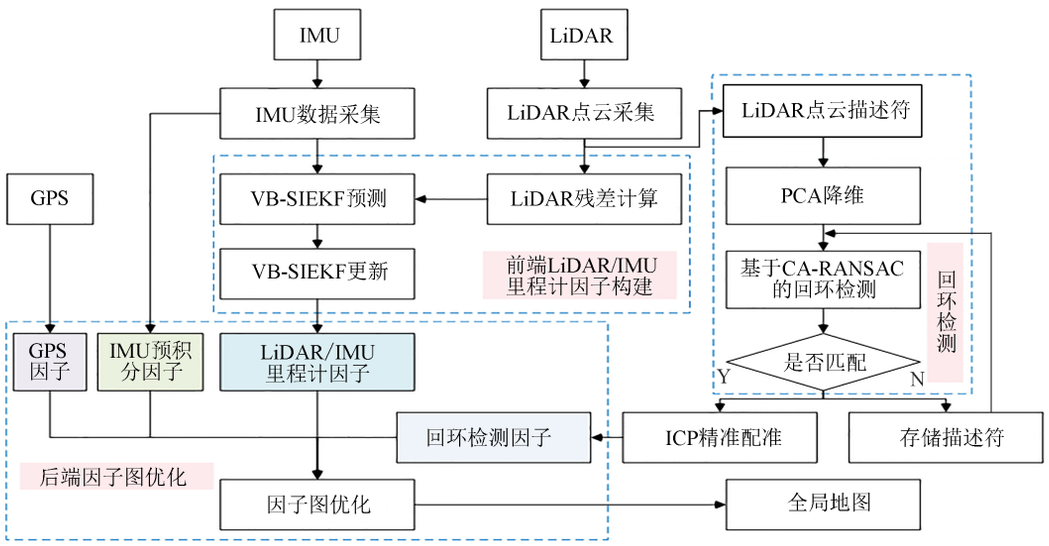

图 1　本文算法整体框架

Fig. 1　Overall framework of the proposed algorithm

够根据实际观测残差动态调整噪声模型参数，避免了传统方法因噪声建模不准确而导致的滤波发散或精度下降问题，从而实现更加稳定和精确的状态估计。

首先，定义系统状态向量$\boldsymbol{x}_k$为

$$\boldsymbol{x}_k=[\boldsymbol{p}_k^{\mathrm{T}},\boldsymbol{v}_k^{\mathrm{T}},\boldsymbol{q}_k^{\mathrm{T}},\boldsymbol{b}_{\mathrm{a}}^{\mathrm{T}},\boldsymbol{b}_{\mathrm{g}}^{\mathrm{T}}]^{\mathrm{T}} \tag{1}$$

式中：$\boldsymbol{p}_k\in\mathbb{R}^3$为$k$时刻的系统位置向量；$\boldsymbol{v}_k\in\mathbb{R}^3$为速度向量；$\boldsymbol{q}_k\in\mathrm{SO}(3)$为四元数姿态；$\boldsymbol{b}_{\mathrm{a}}\in\mathbb{R}^3$为加速度计偏置；$\boldsymbol{b}_{\mathrm{g}}\in\mathbb{R}^3$为陀螺仪偏置。

在贝叶斯统计中，逆伽马分布通常作为高斯分布未知方差的共轭先验分布。因此，观测噪声$\boldsymbol{R}_k$服从逆伽马分布，数学表达式为

$$\boldsymbol{R}_k\sim\mathrm{Inv-Gamma}(\alpha_{k,i},\beta_{k,i}) \tag{2}$$

式中：$\alpha_{k,i}=\bar{\alpha}_{k,i}+0.5$为形状参数，表示逆伽马分布的形状；$\beta_{k,i}=\bar{\beta}_{k,i}+(\boldsymbol{y}_k-h(\delta\boldsymbol{x}_k))_i^2/2+(\boldsymbol{H}_k\boldsymbol{P}_k\cdot\boldsymbol{H}_k^{\mathrm{T}})_i/2$为尺度参数残差影响。其中，$\bar{\alpha}_{k,i}$和$\bar{\beta}_{k,i}$分别为先验形状参数和先验尺度参数，由问题先验知识（如历史数据、传感器特性）和精度信息确定；$\boldsymbol{y}_k$为观测向量；$\delta\boldsymbol{x}_k$为状态向量增量；$h(\cdot)$为观测模型函数，将状态增量映射到观测空间；$\boldsymbol{H}_k$为观测矩阵；$\boldsymbol{P}_k$为协方差矩阵。

变分贝叶斯根据实际观测的残差，对观测噪声协方差矩阵$\boldsymbol{R}_k$进行动态估计和调整，使滤波器更适应当前环境变化。$\boldsymbol{Q}_k$为过程噪声协方差矩阵，用于描述系统状态转移过程中噪声的统计特性，可通过传感器标定、先验知识或固定模型确定。相关更新公式为

$$\hat{\boldsymbol{R}}_k=\mathrm{diag}\left(\frac{\beta_{k,i}}{\alpha_{k,i}}\right)\quad i=1,2,\cdots,m \tag{3}$$

$$\boldsymbol{Q}_k=\mathrm{diag}(\sigma_{\mathrm{g},k}^2,\sigma_{\mathrm{a},k}^2,\sigma_{b_{\mathrm{g}},k}^2,\sigma_{b_{\mathrm{a}},k}^2) \tag{4}$$

式中：$\hat{\boldsymbol{R}}_k$为观测噪声协方差矩阵的估计值；$\sigma_{\mathrm{g},k}$为陀螺仪的噪声协方差；$\sigma_{\mathrm{a},k}$为加速度计的噪声协方差；$\sigma_{b_{\mathrm{g}},k}$、$\sigma_{b_{\mathrm{a}},k}$分别为陀螺仪偏置噪声和加速度计偏置噪声的方差；$m$为观测向量$\boldsymbol{y}_k$的维度。

预测阶段利用IMU数据更新状态和协方差，公式为

$$\begin{cases}\hat{\boldsymbol{x}}_{k|k-1}=\boldsymbol{A}_k\cdot\hat{\boldsymbol{x}}_{k-1|k-1}+\boldsymbol{B}_k\cdot\boldsymbol{u}_k\\ \boldsymbol{P}_{k|k-1}=\boldsymbol{A}_k\cdot\boldsymbol{P}_{k-1|k-1}\cdot\boldsymbol{A}_k^{\mathrm{T}}+\boldsymbol{Q}_k\end{cases} \tag{5}$$

式中：$\hat{\boldsymbol{x}}_{k|k-1}$为$k$时刻对系统状态的先验估计值；$\hat{\boldsymbol{x}}_{k-1|k-1}$为$k-1$时刻对系统状态的后验估计值；$\boldsymbol{P}_{k|k-1}$为$k$时刻协方差的先验估计值；$\boldsymbol{P}_{k-1|k-1}$为$k-1$时刻协方差的后验估计值；$\boldsymbol{A}_k$为状态转移矩阵；$\boldsymbol{B}_k$为控制输入矩阵；$\boldsymbol{u}_k$为控制输入。具体形式为

$$\boldsymbol{A}_k=\begin{bmatrix}\boldsymbol{I}_{3\times3}&\boldsymbol{I}_{3\times3}\Delta t&\boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}\\ \boldsymbol{0}_{3\times3}&\boldsymbol{I}_{3\times3}&\boldsymbol{0}_{3\times3}&-\boldsymbol{C}_{k-1}\Delta t&\boldsymbol{0}_{3\times3}\\ \boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{I}_{3\times3}&\boldsymbol{0}_{3\times3}&-\boldsymbol{I}_{3\times3}\Delta t\\ \boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{I}_{3\times3}&\boldsymbol{0}_{3\times3}\\ \boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}&\boldsymbol{I}_{3\times3}\end{bmatrix} \tag{6}$$

$$\boldsymbol{B}_k=\begin{bmatrix}\frac{1}{2}\boldsymbol{C}_{k-1}\Delta t^2&\boldsymbol{0}_{3\times3}\\ \boldsymbol{C}_{k-1}\Delta t&\boldsymbol{0}_{3\times3}\\ \boldsymbol{0}_{3\times3}&\boldsymbol{I}_{3\times3}\Delta t\\ \boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}\\ \boldsymbol{0}_{3\times3}&\boldsymbol{0}_{3\times3}\end{bmatrix} \tag{7}$$

$$\boldsymbol{u}_k = \begin{bmatrix} \boldsymbol{a}_{\mathrm{m},k} - \boldsymbol{b}_{\mathrm{a},k-1} \\ \boldsymbol{\omega}_{\mathrm{m},k} - \boldsymbol{b}_{\mathrm{g},k-1} \end{bmatrix} \tag{8}$$

式中：Δt为时间间隔；$\boldsymbol{C}_{k-1}$为$k-1$时刻的载体坐标系至东北天坐标系的旋转矩阵；$\boldsymbol{a}_{\mathrm{m},k}$和$\boldsymbol{\omega}_{\mathrm{m},k}$分别为加速度计和陀螺仪的原始测量值。

根据LiDAR点云的边缘和平面特征，在扫描后，计算测量残差并更新状态为

$$\begin{cases} \hat{\boldsymbol{x}}_{k|k} = \hat{\boldsymbol{x}}_{k|k-1} + \boldsymbol{K}_k \cdot (\boldsymbol{z}_k - \boldsymbol{H}_k \cdot \hat{\boldsymbol{x}}_{k|k-1}) \\ \boldsymbol{P}_{k|k} = (\boldsymbol{I} - \boldsymbol{K}_k \cdot \boldsymbol{H}_k) \cdot \boldsymbol{P}_{k|k-1} \end{cases} \tag{9}$$

式中：观测向量$\boldsymbol{z}_k$表示LiDAR点云的边缘和平面特征残差，包括位置和速度相关测量。卡尔曼增益矩阵为$\boldsymbol{K}_k = \boldsymbol{P}_{k|k-1} \cdot \boldsymbol{H}_k^{\mathrm{T}} \cdot (\boldsymbol{H}_k \cdot \boldsymbol{P}_{k|k-1} \cdot \boldsymbol{H}_k^{\mathrm{T}} + \boldsymbol{R}_k)^{-1}$。

2.2 LiDAR/IMU里程计因子构建

LiDAR/IMU里程计因子描述了相邻时间步之间的相对运动约束，是因子图中的核心局部约束。本文中的里程计因子采用基于VB-SIEKF融合的LiDAR/IMU数据，提供高精度的短时内相对位姿变换估计。里程计因子可表示为

$$\boldsymbol{z}_{\mathrm{lio}} = f(\delta x_k, \boldsymbol{Q}_k) \tag{10}$$

式中：$f(\cdot)$为运动模型。

对于相邻时间步i和j，里程计因子的误差项可以定义为

$$\boldsymbol{e}_{\mathrm{lio}}(\boldsymbol{x}_i, \boldsymbol{x}_j) = \log\left[\boldsymbol{T}_{ij}^{\mathrm{meas}} \odot (\boldsymbol{T}_i^{-1} \circ \boldsymbol{T}_j)\right]^{\vee} \tag{11}$$

式中：$\boldsymbol{T}_i$和$\boldsymbol{T}_j$分别为i和j时刻的位姿变换矩阵；$\boldsymbol{T}_{ij}^{\mathrm{meas}}$为里程计测量的相对变换；$\boldsymbol{T}_i^{-1} \circ \boldsymbol{T}_j$表示从状态估计得到的相对变换；$\odot$表示SE(3)上的逆运算；$\circ$表示SE(3)上的复合运算；$(\cdot)^{\vee}$表示SE(3)到se(3)的对数映射。

对应的马氏距离为

$$\left\|\boldsymbol{e}_{\mathrm{lio}}(\boldsymbol{x}_i, \boldsymbol{x}_j)\right\|_{\boldsymbol{\Sigma}_{\mathrm{lio}}}^2 = \boldsymbol{e}_{\mathrm{lio}}^{\mathrm{T}}(\boldsymbol{x}_i, \boldsymbol{x}_j) \boldsymbol{\Sigma}_{\mathrm{lio}}^{-1} \boldsymbol{e}_{\mathrm{lio}}(\boldsymbol{x}_i, \boldsymbol{x}_j) \tag{12}$$

式中：$\|\cdot\|_{\boldsymbol{\Sigma}_{\mathrm{lio}}}^2$为基于协方差矩阵$\boldsymbol{\Sigma}_{\mathrm{lio}}$的马氏距离平方范数；$\boldsymbol{\Sigma}_{\mathrm{lio}}$为LiDAR/IMU里程计因子的协方差矩阵。

3 基于CA-RANSAC的回环检测因子

回环检测技术通过识别无人车重复访问的历史位置，为因子图优化框架提供了跨越时间维度的全局约束信息。当系统成功检测到回环时，相当于在时间上相距较远但空间位置相近的2个关键帧之间建立起直接的几何约束关系。

如图1中回环检测框中所示，本文设计的回环检测模块包括以下关键步骤：首先，构建高效的LiDAR点云描述符以实现快速场景表征；然后，采用主成分分析法（principal component analysis，PCA）优化特征维度；接着，采用CA-RANSAC算法进行特征匹配；最后，通过迭代最近点算法（iterative closest point，ICP）精确配准并获得准确的回环约束。

3.1 LiDAR点云描述符构建

回环检测的关键步骤是构建高效的点云描述符以实现快速准确的场景匹配。本文采用基于空间分割的圆柱形区域描述方法，将雷达点云按水平距离和角度划分为多个圆柱形区域，每个区域的特征为高度与反射强度的均值和标准差，对于每个圆柱形区域i，其特征向量可定义为

$$\boldsymbol{\phi}_i = [\mu_{\mathrm{h},i}, \sigma_{\mathrm{h},i}, \mu_{\mathrm{r},i}, \sigma_{\mathrm{r},i}]^{\mathrm{T}} \tag{13}$$

式中：$\mu_{\mathrm{h},i}$和$\sigma_{\mathrm{h},i}$分别为i区域内点的高度均值和标准差；$\mu_{\mathrm{r},i}$和$\sigma_{\mathrm{r},i}$分别为i区域内LiDAR点云反射强度的均值和标准差。

这种描述符不仅编码了区域的几何形状，同时融合了反射强度信息，能够更全面地表征环境特征。相比传统点特征，圆柱描述符能更精确地编码局部形状信息，具有更强的区分能力，从而显著提升匹配成功率。

3.2 基于PCA的特征降维

圆柱形区域描述符通过融合高度和反射强度信息，能够有效表征局部环境特征。然而，这种描述符在复杂大规模环境中面临2个实际问题：一是特征维度较高带来的计算负担；二是在相似环境中的区分能力有限。

为了在保持识别精度的同时有效提升计算效率，采用PCA对原始特征向量进行降维处理，通过正交变换将高维特征向量投影到低维空间，同时保留最大方差信息，以区分不同圆柱体的特征。通过PCA降维，系统能够在保留关键识别信息的同时显著降低描述符的维度，减少后续处理的计算复杂度，并提高特征匹配的效率和准确性。

3.3 基于CA-RANSAC的回环检测

PCA降维方法虽能有效减少特征维度并保留主要信息，但回环检测的成功与否还取决于特征匹配算法的可靠性。传统方法通常采用RANSAC算法进行几何验证，但其固定阈值机制存在明显的局限性。固定阈值机制在面对环境特征变化时往往无法有效适应，容易产生2类关键错误：一是

将真实的回环位置误判为非回环，导致丢失宝贵的全局约束机会；二是将不同的位置错误匹配为回环，引入错误的约束信息。

为解决这一问题，本文提出基于CA-RANSAC的回环检测算法，通过动态阈值和共识度评估显著提高回环检测的成功率。共识度用来衡量数据点与其他点对当前模型的一致支持程度，使算法可以根据当前的观测情况动态决定哪些点应当被视为内点，从而避免了传统RANSAC中固定阈值导致的误判问题。

首先，通过从数据中随机选择最小样本集来估计初步模型。对一组点对$\{\boldsymbol{p}_{\text{current}}, \boldsymbol{p}_{\text{history}}\}$，使用本质矩阵$\boldsymbol{E}$作为模型，估计过程为

$$\boldsymbol{E} = \text{estimateModel}\left(\{\boldsymbol{p}_{\text{current}}, \boldsymbol{p}_{\text{history}}\}, S\right) \tag{14}$$

式中：$\boldsymbol{p}_{\text{current}}$为当前帧的点云数据；$\boldsymbol{p}_{\text{history}}$为历史帧的点云数据；$S$为一个包含最小样本点的集合；estimateModel（·）表示用于估计模型的函数，输出的本质矩阵$\boldsymbol{E}$使得$\boldsymbol{p}_{\text{current}}$和$\boldsymbol{p}_{\text{history}}$之间关系最大化。

然后，通过计算每个数据点与当前模型的残差来判定数据点是内点还是外点。对于每个点i，其残差r_i为

$$r_i = \left\| \boldsymbol{p}_{\text{current},\,i}^{\mathrm{T}} \boldsymbol{E} \boldsymbol{p}_{\text{history},\,i} \right\| \tag{15}$$

如果r_i小于某个阈值ε，则该点被认为是内点，否则为外点。

CA-RANSAC通过计算点之间的共识度来评估他们对模型的支持程度，表达式为

$$A_{i,j}^{(k)} = \exp\left(-\frac{\left| r_i^{(k)} - r_j^{(k)} \right|^2}{2\sigma_{\text{A}}^2} \right) \tag{16}$$

式中：$A_{i,j}^{(k)}$为点i和j之间第k次迭代的共识度；$r_i^{(k)}$和$r_j^{(k)}$分别为点i和j在第k次迭代后的残差；σ_{A}^2为高斯核的带宽参数。

每个点的内点概率决定了点是否应该被视为内点，表达式为

$$P_{\text{inlier}}(i) = \frac{1}{1 + \mathrm{e}^{-\lambda_{\text{prob}} \sum_{i \neq j} A_{i,j}^{(k)}}} \tag{17}$$

式中：λ_{prob}为调整因子，控制内点概率的敏感度。通过更新内点概率，系统可以动态调整每次迭代的阈值，进一步提高模型的拟合精度。

CA-RANSAC的阈值更新公式为

$$\tau_{\text{adaptive}}^{(k+1)} = \tau_{\text{base}} \cdot \exp\left(-\lambda_{\text{thresh}} \cdot \frac{\sum_{i \in C^{(k)}} w_i^{(k)}}{\left| C^{(k)} \right|} \right) \tag{18}$$

式中：τ_{base}为初始阈值；λ_{thresh}为调整因子；$C^{(k)}$为第k次迭代的候选点集；$w_i^{(k)} = \sum_{i \neq j} A_{i,j}^{(k)}$为点$i$在第$k$次迭代中的共识度权重。在特征丰富且区分度高的环境中，算法会自动收紧匹配阈值，减少误匹配的可能性；而在特征稀疏或相似度较高的环境中，算法会适当放宽阈值，避免遗漏真实的回环信息。

最后，为更加精确地筛选数据，CA-RANSAC使用最大一致子集（maximum consensus subset，MCS）来筛选最优阈值。最大一致子集的优化目标是最大化符合模型的点的数量，计算公式为

$$\varepsilon_{\text{opt}} = \arg\max_{\varepsilon} \sum_{i=1}^{n} I\left(\left| r_i^{(k)} \right| \leqslant \varepsilon \right) \tag{19}$$

式中：I（·）为指示函数，当点i的残差r_i小于等于当前阈值ε时，则返回1，否则返回0。

在每次迭代中，CA-RANSAC根据内点集合重新估计模型，更新后的本质矩阵为

$$\boldsymbol{E}_{\text{refined}} = \text{refineModel}\left(\{\boldsymbol{p}_{\text{current}}, \boldsymbol{p}_{\text{history}}\}, \mathcal{I} \right) \tag{20}$$

式中：refineModel（·）为基于内点集合对模型进行精细化估计的函数，其结合所有符合当前模型的数据，得到比初始随机采样估计更精确的模型参数；$\mathcal{I} = \{ i : \left| r_i^{(k)} \right| < \tau_{\text{adaptive}}^{(k)} \}$为当前被识别为内点的集合。通过反复更新，CA-RANSAC逐渐优化模型并找到最优解。

3.4 ICP配准

CA-RANSAC通过动态阈值调整和共识度评估机制，显著提升了融合定位算法在复杂环境下的匹配可靠性。然而，基于特征点的匹配结果仍然存在一定的几何误差，无法直接满足后端优化对约束精度的要求。为了获得高质量的回环变换矩阵，本文通过CA-RANSAC初步识别出潜在的回环候选帧后，系统随即对其进行ICP精确配准，以获得高精度的回环变换矩阵。

ICP配准通过求解位姿变换矩阵$\boldsymbol{T}_{\text{c}}$，将候选回环帧点云从历史关键帧库变换到当前帧坐标系，同时对$\boldsymbol{T}_{\text{c}}$进行优化，使两帧对应点的欧式残差平方和最小，其目标函数为

$$\min_{\boldsymbol{T}_{\text{c}}} \left\| \boldsymbol{P}_{\text{current}} - \boldsymbol{T}_{\text{c}} \boldsymbol{P}_{\text{candidate}} \right\|_2^2 \tag{21}$$

式中：$\boldsymbol{P}_{\text{current}}$和$\boldsymbol{P}_{\text{candidate}}$分别为当前帧与候选帧的点云矩阵；$\boldsymbol{T}_{\text{c}}$表示把候选帧点云变换到当前帧坐标系的位姿变换矩阵。

ICP通过迭代优化逐步提高配准精度，其过程大致可以分为以下3步：首先，对每个点在另一

个点云中找到最近对应点；其次，计算旋转和平移，使对应点间距离平方和最小化；最后，应用变换并迭代，直至收敛。

3.5 回环检测因子构建

回环检测所识别的帧对为后端优化模块提供了至关重要的全局约束。为了将回环信息有效地整合到因子图优化框架中，本文构建了回环检测因子，使系统能够充分利用回环约束消除LiDAR/IMU里程计长距离的累积误差。

当CA-RANSAC算法成功识别回环匹配且ICP精确配准完成后，回环因子的误差项可表示为

$$\boldsymbol{e}_{\text{loop}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\log\left(\boldsymbol{T}_{\text{loop}}^{-1}\boldsymbol{T}_i^{-1}\boldsymbol{T}_j\right)^{\vee} \tag{22}$$

式中：$\boldsymbol{T}_{\text{loop}}$是通过ICP精确配准后获得的回环变换矩阵。

对应的马氏距离为

$$\left\|\boldsymbol{e}_{\text{loop}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\right\|_{\boldsymbol{\Sigma}_{\text{loop}}}^{2}=\boldsymbol{e}_{\text{loop}}^{\text{T}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\boldsymbol{\Sigma}_{\text{loop}}^{-1}\boldsymbol{e}_{\text{loop}}(\boldsymbol{x}_i,\boldsymbol{x}_j) \tag{23}$$

式中：$\boldsymbol{\Sigma}_{\text{loop}}$为回环检测因子的协方差矩阵。

CA-RANSAC通过自适应阈值调整和共识度评估构成的双重保障机制，确保了系统能够在不同复杂度的环境中都保持高质量的回环检测性能。此外，CA-RANSAC建立的高质量回环约束能够更有效地传播到整个优化模块。

在因子图优化过程中，将每个回环因子的信息矩阵定义为

$$\boldsymbol{\Omega}_{\text{loop}}=\lambda_{\text{quality}}\cdot\boldsymbol{\Omega}_{\text{base}} \tag{24}$$

式中：λ_{quality}表示基于CA-RANSAC检测质量的置信度因子；$\boldsymbol{\Omega}_{\text{base}}$为基础信息矩阵。

高精度的回环检测结果意味着更大的λ_{quality}值和更高的约束权重，使得优化算法能够更大程度地依赖这些全局约束来调整局部轨迹估计。相反，如果回环检测存在较大误差或不确定性，λ_{quality}会相应降低，从而削弱累积误差消除的效果。因此，CA-RANSAC通过提升回环检测的基础质量，间接有效地增强了整个融合定位系统抑制长距离累积误差的能力。

回环检测因子虽能提供跨时间维度的全局约束，但其作用具有间歇性和条件性，在无回环或回环检测失效的时段内无法发挥作用。为此，本文构建了一个完整的多源传感器融合优化模块，引入GPS因子提供持续的全局位置基准以抑制长期漂移误差，同时引用IMU预积分因子来充分利用其高频特性，确保状态估计的时间连续性和平滑性。

4 因子图优化

后端优化模块的核心任务是统一处理来自前端融合的LiDAR/IMU里程计约束、回环检测的全局约束、GPS的绝对位置约束以及IMU的运动连续性约束，通过因子图优化实现系统级的误差抑制和全局一致性求解。

4.1 GPS因子构建

GPS提供了全局参考框架下的绝对位置信息，是抑制长距离累积误差的重要数据源。GPS因子将卫星定位结果与位姿估计间的差异建模为

$$\boldsymbol{z}_{\text{gps}}=\boldsymbol{x}_{\text{gps}}-(\boldsymbol{x}_{\text{est}}-\boldsymbol{x}_{\text{ref}}) \tag{25}$$

式中：$\boldsymbol{x}_{\text{gps}}$为GPS测量值；$\boldsymbol{x}_{\text{est}}$为估计值；$\boldsymbol{x}_{\text{ref}}$为参考值。

将GPS因子的误差项定义为

$$\boldsymbol{e}_{\text{gps}}(\boldsymbol{x})=\boldsymbol{x}_{\text{pos}}-\boldsymbol{x}_{\text{gps}} \tag{26}$$

式中：$\boldsymbol{x}_{\text{pos}}$为理论值。

对应的马氏距离为

$$\left\|\boldsymbol{e}_{\text{gps}}(\boldsymbol{x})\right\|_{\boldsymbol{\Sigma}_{\text{gps}}}^{2}=\boldsymbol{e}_{\text{gps}}^{\text{T}}(\boldsymbol{x})\boldsymbol{\Sigma}_{\text{gps}}^{-1}\boldsymbol{e}_{\text{gps}}(\boldsymbol{x}) \tag{27}$$

式中：$\boldsymbol{\Sigma}_{\text{gps}}$为GPS因子的协方差矩阵。

4.2 IMU预积分因子构建

IMU的角速度和线加速度测量值的更新频率远高于LiDAR和GPS。为高效利用这些高频数据，本文采用IMU预积分因子，将相邻关键帧间的多个IMU测量值压缩为单个预积分测量值。

IMU预积分因子的表达式为

$$\boldsymbol{z}_{\text{imu}}=\int_{t_{k-1}}^{t_k}(\boldsymbol{a}_{\text{m}}-\boldsymbol{b}_{\text{a}}-\boldsymbol{n}_{\text{a}})\,\text{d}t+\boldsymbol{\omega}_{\text{m}}\times(\boldsymbol{p}_{\text{m}}-\boldsymbol{b}_{\text{g}}-\boldsymbol{n}_{\text{g}}) \tag{28}$$

式中：$\boldsymbol{a}_{\text{m}}$和$\boldsymbol{\omega}_{\text{m}}$分别为加速度计和陀螺仪的测量值；$\boldsymbol{n}_{\text{a}}$和$\boldsymbol{n}_{\text{g}}$分别为加速度计和陀螺仪的噪声。

在预积分过程中，假设偏置在相邻关键帧之间保持不变，从而可以独立于位姿状态进行积分计算。IMU预积分因子的误差项包括相对旋转、速度和位置，分别为

$$\boldsymbol{e}_{\text{c}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\log\left(\Delta\boldsymbol{C}_{ij}^{-1}\cdot\boldsymbol{C}_i^{-1}\cdot\boldsymbol{C}_j\right)^{\vee} \tag{29}$$

$$\boldsymbol{e}_{\text{v}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\boldsymbol{C}_i^{-1}(\boldsymbol{v}_j-\boldsymbol{v}_i-g\Delta t_{ij})-\Delta\boldsymbol{v}_{ij} \tag{30}$$

$$\boldsymbol{e}_{\text{p}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\boldsymbol{C}_i^{-1}\left(\boldsymbol{p}_j-\boldsymbol{p}_i-\boldsymbol{v}_i\Delta t_{ij}-\frac{1}{2}g\Delta t_{ij}^2\right)-\Delta\boldsymbol{p}_{ij} \tag{31}$$

式中：Δt_{ij}为第i帧和第j帧的时间差；$\boldsymbol{C}_i$和$\boldsymbol{C}_j$分别为第i帧和第j帧的旋转矩阵；$\Delta\boldsymbol{C}_{ij}$、$\Delta\boldsymbol{v}_{ij}$和$\Delta\boldsymbol{p}_{ij}$分别为预积分得到的第$i$帧和第$j$帧的相对旋转、速

度和位置变化；$\boldsymbol{p}_i$和$\boldsymbol{p}_j$分别为第i帧和第j帧对应的车辆位置；$\boldsymbol{v}_i$和$\boldsymbol{v}_j$分别为第i帧和第j帧对应的车辆速度；g为重力加速度。

IMU预积分因子的残差向量为

$$\boldsymbol{e}_{\text{imu}}(\boldsymbol{x}_i,\boldsymbol{x}_j)=\begin{bmatrix}\boldsymbol{e}_{\text{c}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\\ \boldsymbol{e}_{\text{v}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\\ \boldsymbol{e}_{\text{p}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\end{bmatrix} \tag{32}$$

对应的马氏距离为

$$\left\|\boldsymbol{e}_{\text{imu}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\right\|^2_{\boldsymbol{\Sigma}_{\text{imu}}}=\boldsymbol{e}^{\text{T}}_{\text{imu}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\boldsymbol{\Sigma}^{-1}_{\text{imu}}\boldsymbol{e}_{\text{imu}}(\boldsymbol{x}_i,\boldsymbol{x}_j) \tag{33}$$

式中：$\boldsymbol{\Sigma}_{\text{imu}}$为IMU预积分因子的协方差矩阵。

4.3 后端因子图构建

后端优化模块将上述异构约束信息统一整合到因子图模块，以实现全局一致性求解，完整的因子图模型如图2所示。图中，GPS因子提供全局位置约束，抑制长距离累积误差；LiDAR/IMU里程计因子描述相邻时间步之间的相对运动关系，保证局部轨迹的高精度连续性；IMU预积分因子高频模拟连续运动特性，充分利用了惯性测量的时间密度优势；回环检测因子提供跨时间维度的全局一致性约束，有效修正长距离漂移。这4类因子在时间和空间维度上相互补充，通过非线性优化实现多源信息的协同定位，系统能够充分利用多源传感器的互补优势，实现全局一致的位姿估计，有效解决了传统里程计长距离运行中的累积误差问题。尤其是当系统检测到回环时，回环因子提供的约束能够显著修正长距离累积的漂移误差，使整个轨迹和地图保持全局一致。

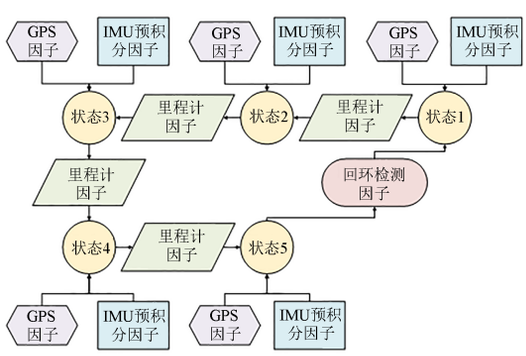

图2 因子图模型

Fig. 2 Factor graph model

综上所述，构建完整的因子图优化问题为

$$\boldsymbol{X}^*=\arg\min_{\boldsymbol{X}}\left\{\sum_{i,j}\left\|\boldsymbol{e}_{\text{lio}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\right\|^2_{\boldsymbol{\Sigma}_{\text{lio}}}+\sum_{i,j}\left\|\boldsymbol{e}_{\text{imu}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\right\|^2_{\boldsymbol{\Sigma}_{\text{imu}}}+\sum_{i}\left\|\boldsymbol{e}_{\text{gps}}(\boldsymbol{x}_i)\right\|^2_{\boldsymbol{\Sigma}_{\text{gps}}}+\sum_{i,j}\left\|\boldsymbol{e}_{\text{loop}}(\boldsymbol{x}_i,\boldsymbol{x}_j)\right\|^2_{\boldsymbol{\Sigma}_{\text{loop}}}\right\} \tag{34}$$

式中：$\boldsymbol{X}^*$为优化后的系统状态向量集合。

对于这类非线性最小二乘问题，本文采用高斯-牛顿法进行求解。相比牛顿法，高斯-牛顿法收敛速度快，计算复杂度低，在良好初值条件下能保证局部最优解。

5 实验与分析

为评估所提方法在不同环境条件下的目标定位性能，本文将基于CA-RANSAC的多传感器融合定位方法分别与单独使用基于VB-SIEKF的LiDAR/IMU里程计方法和基于常规RANSAC进行回环检测的融合定位方法进行实验对比。

5.1 数据来源

本文选择卡尔斯鲁厄理工学院和芝加哥丰田技术研究所（Karlsruhe Institute of Technology and Toyota Technological Institute at Chicago，KITTI）数据集[24]中的多个具有代表性的序列进行实验验证，主要采用序列00、05和07。序列00为城市道路场景，采用双向两车道设计，路面平坦且GPS信号良好，包含2个明显回环路径；序列05为乡村道路场景，环境开阔，交通流稀少，GPS信号质量优秀，包含1个大型回环（间距约1.5 km）；序列07为城市中心场景，高楼密集，交通流量大，GPS信号质量较差且存在多径效应，无明显回环结构。3个测试序列覆盖了不同环境类型、交通复杂度和GPS信号质量，包含多样化的回环结构，全面覆盖了融合定位算法面临的主要技术挑战，从而确保实验验证的全面性和结论的可靠性。

5.2 数据处理与分析

本文从以下3个维度来评估算法性能：1）采用位置误差来分析算法的绝对精度，可以全面评估算法在各方向的定位能力；2）分析相对位姿误差以揭示算法在短时内的相对定位稳定性；3）回环检测重定位准确率能够检测算法消除累积误差的能力。

5.2.1 位置误差分析

3种算法在不同场景下的东北天位置误差如图3～图5所示。

从图3～图5可以看出，CA-RANSAC算法在序列00和05中的平均位置误差均明显小于其他2

种算法，误差曲线始终保持在较低水平且接近于零线；在序列 05 中，虽然 3 种方法的误差曲线较为接近，但 CA-RANSAC 的误差曲线周期性波动，表明算法的稳定性较好。相比之下，VB-SIEKF 算法由于缺乏回环检测机制，误差曲线波动幅度较大，在某些时段内出现明显偏移。传统 RANSAC 算法虽然引入了回环检测功能，但由于固定阈值机制的局限性，误差控制效果介于两者之间。

3 种算法的位置误差统计结果如表 1 所示。

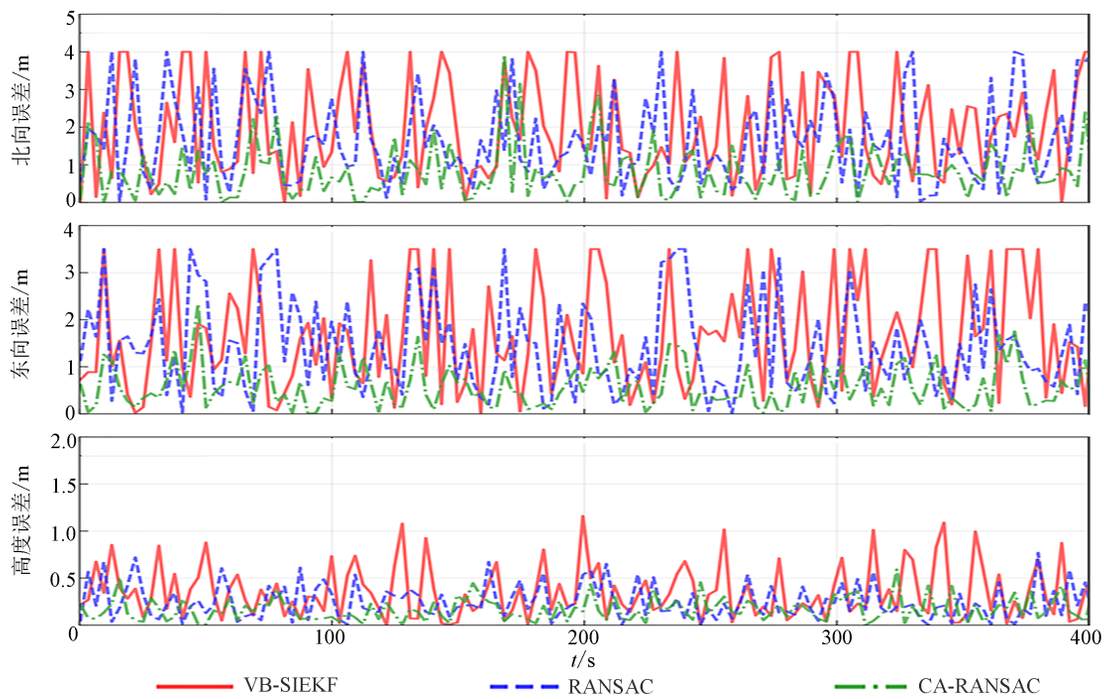

图 3　序列 00 测试场景下车辆位置误差曲线

Fig. 3　Vehicle position error curves in the sequence 00 testing scenario

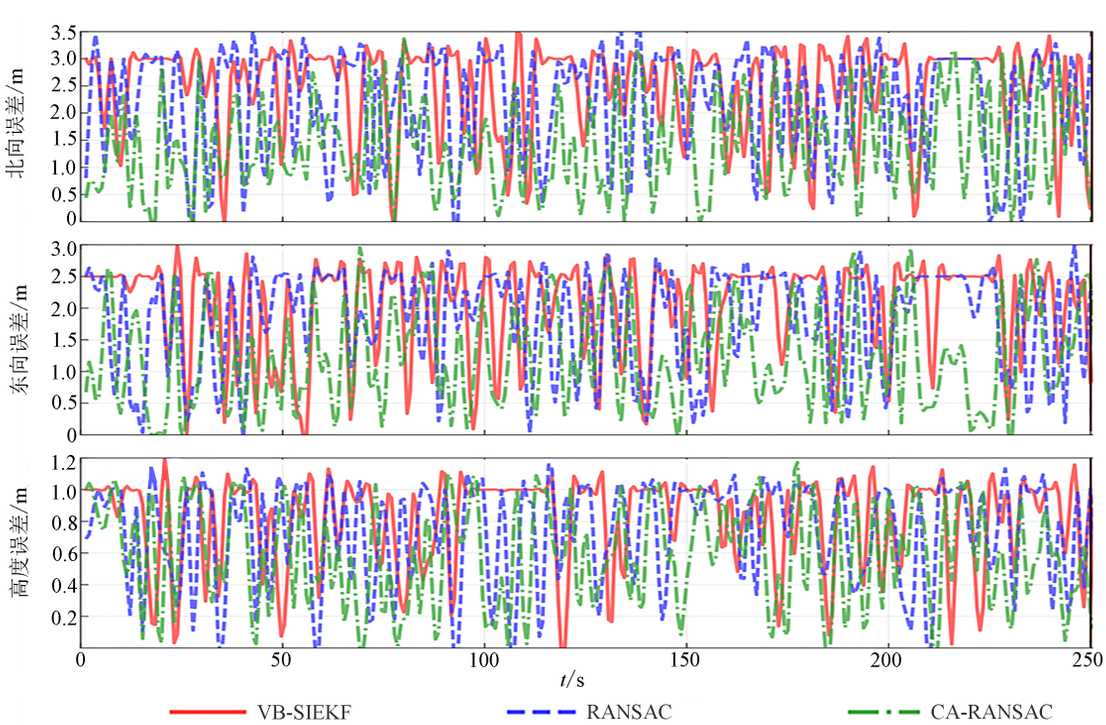

图 4　序列 05 测试场景下车辆位置误差曲线

Fig. 4　Vehicle position error curves in the sequence 05 testing scenario

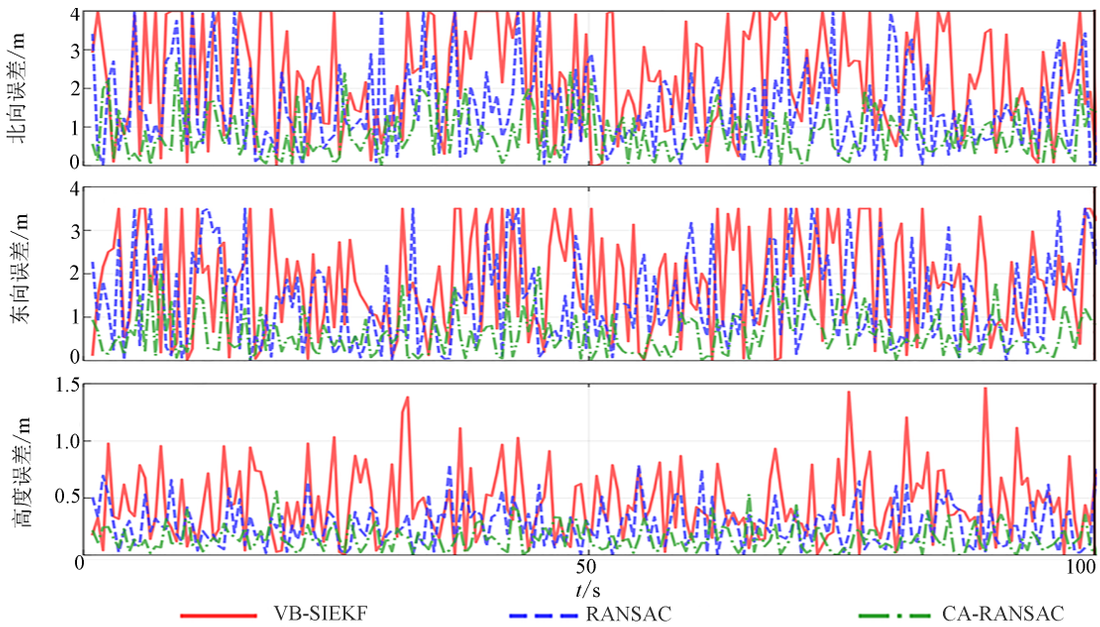

图 5　序列 07 测试场景下车辆位置误差曲线

Fig. 5　Vehicle position error curves in the sequence 07 testing scenario

表 1　不同测试场景下车辆位置误差统计结果

Table 1　Statistics of vehicle position errors in different testing scenarios

序列	算法	均方根误差/m	平均绝对误差/m	中位数误差/m	最大误差/m	标准差/m
00	VB-SIEKF	1.680	1.525	1.445	4.115	0.704
	RANSAC	1.103	0.991	0.908	2.493	0.483
	CA-RANSAC	0.558	0.509	0.480	1.234	0.229
05	VB-SIEKF	1.359	1.232	1.152	3.199	0.572
	RANSAC	0.895	0.800	0.752	2.336	0.402
	CA-RANSAC	0.442	0.401	0.371	1.124	0.186
07	VB-SIEKF	2.130	1.924	1.794	4.019	0.913
	RANSAC	1.504	1.328	1.135	3.574	0.706
	CA-RANSAC	0.721	0.643	0.565	1.673	0.324

表1同时给出了多个误差评价指标，其定量数据进一步证实了上述曲线的观察结果。其中，均方根误差体现了算法的总体定位误差，是主要的评价指标；平均绝对误差和中位数误差反映了算法的常态表现；标准差反映算法的稳定性。

在序列00中，CA-RANSAC算法的均方根误差为0.558 m，相比VB-SIEKF与传统RANSAC算法分别降低了66.8%和49.4%。在序列05中，CA-RANSAC算法的表现更加突出，其均方根误差降至0.442 m，相比VB-SIEKF和传统RANSAC算法分别降低了67.5%和50.6%。在序列07中，CA-RANSAC的均方根误差仍然保持在较低水平，相比VB-SIEKF和传统RANSAC算法分别降低了66.2%和52.1%。

综上所述，相比其他2种定位方法，CA-RANSAC在3种场景下的均方根误差均相对最低，且最大误差和标准差都有显著下降，这是由于其自适应阈值机制能够根据环境特征动态调整匹配参数，减少了传统固定阈值方法在特征稀疏或相似环境下的误判。同时，共识度评估策略通过计算点间的支持强度，进一步筛选出高质量的匹配对，从而为后端优化提供了更加可靠的约束信息。

5.2.2　相对位姿误差分析

3种算法在不同场景下的相对位姿误差随时间的变化曲线如图6所示。

从图6中位姿误差曲线的整体趋势来看，VB-SIEKF算法在所有测试序列中都表现出明显的不稳定特征，误差曲线存在十分剧烈的波动现象，波峰频繁出现且峰值较大，这种现象直接反映了其缺乏回环检测机制所导致的累积误差持续增长的问题。传统RANSAC融合算法虽然相比VB-SIEKF有所改善，但其位姿误差曲线仍然存在明显的周期性波动，特别是在某些特定时段内出现了明显的误差峰值，这主要归因于固定阈值机制无法有效适应环境变化所造成的匹配失效。

相比之下，CA-RANSAC融合算法的误差曲

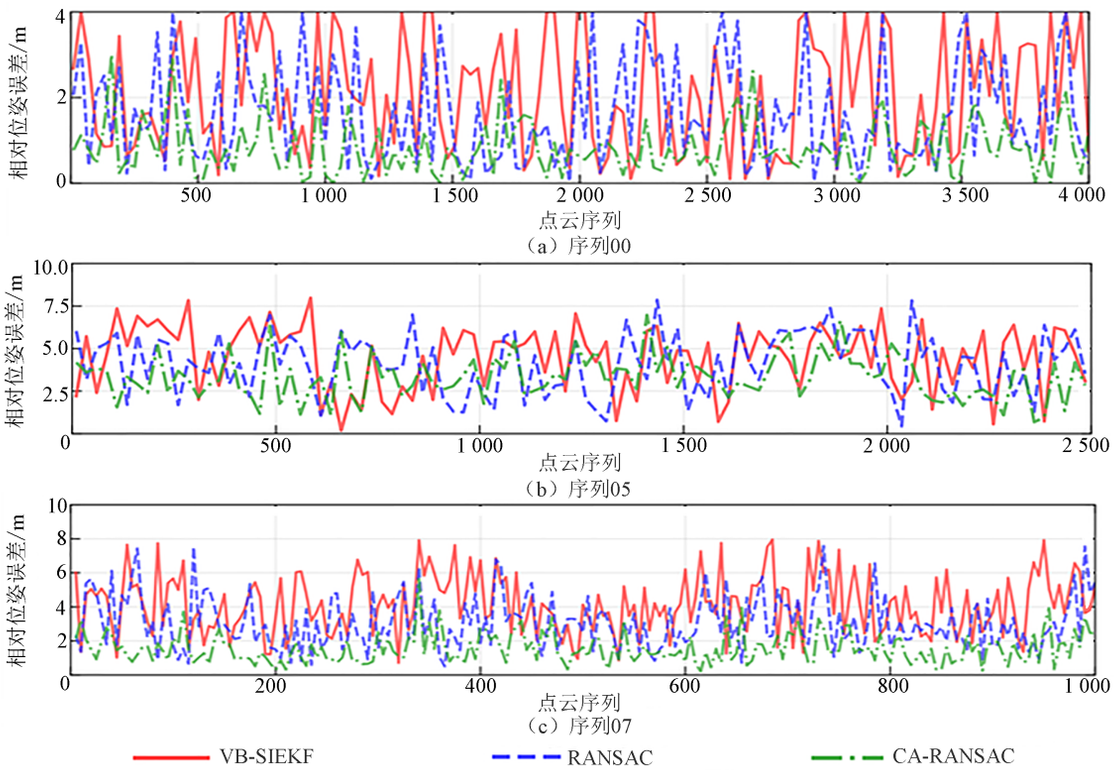

图 6　不同测试场景下车辆相对位姿误差曲线

Fig. 6　Vehicle relative pose error curves in different testing scenarios

线表现出卓越的稳定性和一致性。在3个不同的测试序列中，该算法都能将位姿误差曲线控制在相对较低的水平，且波动幅度明显减小，整体趋势更加平滑。这种优异的表现充分证明了CA-RANSAC自适应阈值调整机制和共识度评估策略的有效性。该方法能够根据环境特征的变化动态调整匹配参数，从而在各种复杂场景下都保持相对稳定的位姿估计精度。

3种算法在不同场景下的相对位姿误差统计结果如表2所示。

由表2可得，相较于VB-SIEKF算法，CA-RANSAC 的相对位姿均方根误差在00、05和07序列上的降幅分别为66.0%、67.0%和66.6%；同时，相较于传统RANSAC融合定位方法，CA-RANSAC 的相对位姿均方根误差在00、05和07序列上的降幅分别为49.6%、49.5%和54.9%，表明CA-RANSAC融合算法的误差曲线表现出卓越的稳定性和一致性。

5.2.3　回环检测重定位成功率

3种算法在不同场景下的回环检测重定位成功率如表3所示。其中，回环检测重定位成功率是评估SLAM系统性能的核心指标，直接反映了系统修正累积误差、维持全局地图一致性的能力。

表 2　不同测试场景下车辆相对位姿误差统计结果

Table 2　Statistics of vehicle relative pose errors in different testing scenarios

序列	算法	平均相对误差/m	中位数误差/m	均方根误差/m	标准差/m	最大误差/m
00	VB-SIEKF	2.101 2	1.988 6	2.334 0	1.015 1	5.884 5
	RANSAC	1.408 5	1.313 7	1.573 9	0.701 6	3.757 6
	CA-RANSAC	0.724 2	0.678 6	0.793 1	0.323 4	1.877 8
05	VB-SIEKF	1.729 4	1.591 7	1.920 0	0.834 1	5.207 6
	RANSAC	1.120 8	1.041 2	1.253 4	0.561 1	3.515 4
	CA-RANSAC	0.569 7	0.507 4	0.633 4	0.276 7	1.627 4
07	VB-SIEKF	2.654 1	2.627 1	2.904 7	1.182 4	7.188 7
	RANSAC	1.928 1	1.796 8	2.152 8	0.959 2	5.117 7
	CA-RANSAC	0.869 4	0.742 5	0.970 7	0.430 6	2.457 0

从表3可以直观看到，VB-SIEKF算法因完全缺乏回环检测功能，回环检测成功率均为0。而传统RANSAC融合算法在3个场景中的回环检测成功率分别为68.0%、68.3%和66.7%，但均伴随着28.5%～38.0%的较高误匹配率。相比之下，CA-RANSAC在3个场景中的回环检测成功率分别为94.2%、86.7%和88.0%，同时将误匹配率控

制在6.7%、9.2%和3.0%的低水平。相比传统RANSAC的回环检测成功率提升18.4～26.2个百分点，误匹配率降低19.3～31.3个百分点。这种优异表现主要归因于其动态阈值调整机制能够根据环境特征自适应调整匹配参数，且共识度评估策略能够有效筛选出高质量的匹配对。

表3 不同测试场景下车辆回环检测成功率与误匹配率统计结果

Table 3 Statistics of vehicle loop closure detection success and mismatch rates in different testing scenarios

序列	算法	回环检测成功率/%	误匹配率/%
00	VB-SIEKF	0	0
	RANSAC	68.0	38.0
	CA-RANSAC	94.2	6.7
05	VB-SIEKF	0	0
	RANSAC	68.3	28.5
	CA-RANSAC	86.7	9.2
07	VB-SIEKF	0	0
	RANSAC	66.7	33.3
	CA-RANSAC	88.0	3.0

6 结论

针对LiDAR/IMU里程计在长距离运行过程中产生的累积误差，本文提出一种基于CA-RANSAC的LiDAR/IMU/GPS融合定位算法，得出以下结论。

1）通过构建融合高度与反射强度信息的圆柱形点云描述符，结合PCA降维技术提升了特征表达能力和计算效率。

2）在回环检测环节引入CA-RANSAC算法，通过共识度评估和自适应阈值调整机制显著提升了匹配可靠性。

3）后端优化模块集成了LiDAR/IMU里程计因子、GPS因子、IMU预积分因子和回环检测因子，通过因子图优化实现了全局一致的位姿估计。

4）在KITTI数据集的3个典型场景中，本文算法的位置均方根误差相比VB-SIEKF和RANSAC降低了49%以上，回环检测成功率高达86.7%以上，误匹配率控制在9.2%以内，充分验证了所提方法的有效性。

参考文献

[1] 张志利，祝慧鑫，周召发，等. 重型车辆高级驾驶辅助系统研究综述[J]. 火箭军工程大学学报，2024，38(3)：94-103，110.
ZHANG Z L，ZHU H X，ZHOU Z F，et al. Review on ADAS technologies for heavy-duty vehicles[J]. Journal of Rocket Force University of Engineering，2024，38(3)：94-103，110.

[2] 王禹，王彬彬，王斐，等. 基于闭环检测和地面优化的激光雷达惯性里程计建图与定位[J]. 仪器仪表学报，2025，46(5)：205-213.
WANG Y，WANG B B，WANG F，et al. Research on the localization and mapping based on closed-loop detection and ground optimization[J]. Chinese Journal of Scientific Instrument，2025，46(5)：205-213.

[3] 黄明明，孙蕊. 城市环境改进点云配准的LiDAR辅助GNSS/IMU定位算法[J/OL]. 北京航空航天大学学报，(2024-10-21)[2025-07-27]. https://doi.org/10.13700/j.bh.1001-5965.2023.0837.
HUANG M M，SUN R. LiDAR aided GNSS/IMU positioning algorithm based on improved point cloud registration[J/OL]. Journal of Beijing University of Aeronautics and Astronautics，(2024-10-21)[2025-07-27]. https://doi.org/10.13700/j.bh.1001-5965.2023.0837.

[4] 张志利，张克凡，赵军阳. 基于高度计位置修正的SINS/GNSS车载重力测量方法[J]. 火箭军工程大学学报，2025，39(2)：39-46.
ZHANG Z L，ZHANG K F，ZHAO J Y. SINS/GNSS vehicle gravity measurement method based on altimeter position correction[J]. Journal of Rocket Force University of Engineering，2025，39(2)：39-46.

[5] 曾庆化，罗怡雪，孙克诚，等. 视觉及其融合惯性的SLAM技术发展综述[J]. 南京航空航天大学学报，2022，54(6)：1007-1020.
ZENG Q H，LUO Y X，SUN K C，et al. Review on SLAM technology development for vision and its fusion of inertial information[J]. Journal of Nanjing University of Aeronautics & Astronautics，2022，54(6)：1007-1020.

[6] HU Y T，ZHOU Q G，MIAO Z J，et al. Outdoor LiDAR-inertial SLAM using ground constraints[J]. Robotica，2024，42(4)：1246-1261.

[7] 张博，张吟龙，梁炜，等. 基于多模态信息融合的仓储AGV的激光惯性导航方法[J]. 光学学报，2024，44(9)：177-189.
ZHANG B，ZHANG Y L，LIANG W，et al. Warehouse AGV navigation based on multimodal information fusion[J]. Acta Optica Sinica，2024，44(9)：177-189.

[8] CHEN S B，MA H，JIANG C H，et al. NDT-LOAM：a real-time LiDAR odometry and mapping with weighted NDT and LFA[J]. IEEE Sensors Journal，2022，22(4)：3660-3671.

[9] 高旺，赵恒，刘宏，等. 基于隐式神经地图的LiDAR/IMU匹配定位算法[J]. 仪器仪表学报，2024，45(12)：74-84.
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.

[10] SHI P C，LI J Y，ZHANG Y J. A fast LiDAR place recognition and localization method by fusing local and global search[J]. ISPRS Journal of Photogrammetry and Remote Sensing，2023，202：637-651.

[11] CAMPOS C，ELVIRA R，RODRÍGUEZ J J G，et al. ORB-SLAM3：an accurate open-source library for visual，visual inertial，and multi-map SLAM[J]. IEEE Transactions on Robotics，2021，37(6)：1874-1890.

[12] 牛国臣，栾向宇. 基于特征点提取的多传感器融合机坪建图方法[J]. 航空学报，2024，45(S1)：437-448.
NIU G C，LUAN X Y. A method for apron mapping based on feature point extraction and multi-sensor fusion[J]. Acta Aeronautica et Astronautica Sinica，2024，45(S1)：437-448.

[13] LIU Y J，WANG C，WU H，et al. An effective LiDAR-inertial SLAM-based map construction method for outdoor environments[J]. Remote Sensing. 2024，16(16)：3099.

[14] 毛清华，柴建权，陈彦璋，等. 激光雷达和IMU融合的煤矿掘进巷道三维重建方法[J]. 煤炭科学技术，2025，53(2)：351-362.
MAO Q H，CHAI J Q，CHEN Y Z，et al. A three-dimensional reconstruction method of coal mine tunnel fused with LiDAR and IMU[J]. Coal Science and Technology，2025，53(2)：351-362.

[15] 李飞翔，阚希，张永宏，等. 基于改进回环和位姿图优化的激光SLAM算法[J/OL]. 激光与光电子学进展，(2025-04-19)[2025-07-27]. https://link.cnki.net/urlid/31.1690.TN.20250409.1017.022.
LI F X，KAN X，ZHANG Y H，et al. Lidar SLAM algorithm based on improved loop closure and pose graph optimization[J/OL]. Laser & Optoelectronics Progress，(2025-04-19)[2025-07-27]. https://link.cnki.net/urlid/31.1690.TN.20250409.1017.022.

[16] ZHANG B S，DONG Y P，QI X Y，et al. PC-IDN：fast 3D loop closure detection using projection context descriptor and incremental dynamic nodes[J]. Measurement，2024，235：114976.

[17] ZHANG X，ZHANG H J，QIAN C，et al. A LiDAR-intensity SLAM and loop closure detection method using an intensity cylindrical-projection shape context descriptor[J]. International Journal of Applied Earth Observation and Geoinformation，2023，122：103419.

[18] GOFFIN S，BARRAU A，BONNABEL S，et al. Iterated invariant extended Kalman filter (IterIEKF)[EB/OL].(2025-05-12)[2025-06-20]. http://arxiv.org/abs/2404.10665.

[19] PAN H M，LIU D F，REN J Z，et al. LiDAR-IMU tightly-coupled SLAM method based on IEKF and loop closure detection[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing，2024，17：6986-7001.

[20] 陈谢发，李敏，赵晶钰，等. 基于双层注意力机制的遥感小目标检测算法[J]. 火箭军工程大学学报，2025，39(1)：60-66.
CHEN X F，LI M，ZHAO J Y，et al. Remote sensing small object detection algorithm based on dual-layer attention mechanism[J]. Journal of Rocket Force University of Engineering，2025，39(1)：60-66.

[21] XIANG H D，SHI W Z，FAN W Z，et al. Fast-LCD：a fast and compact loop closure detection approach using 3D point cloud for indoor mobile mapping[J]. International Journal of Applied Earth Observation and Geoinformation，2021，102：102430.

[22] CAVALLI L，BARATH D，POLLEFEYS M，et al. Consensus-adaptive RANSAC[EB/OL].(2023-07-26)[2025-04-24]. http://arxiv.org/abs/2307.14030.

[23] WANG J L，CHEN Z Y. Variational Bayesian iteration-based invariant Kalman filter for attitude estimation on matrix lie groups[J]. Aerospace，2021，8(9)：246.

[24] 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. Piscataway，NJ，USA：IEEE，2012：3354-3361.

（编辑：刘建民）