

点群・IMU 制約のウィンドウ最適化に基づく既知地図上での 6DoF 姿勢推定

Window-Optimization-based Range-IMU Localization on a 3D Prior Environmental Map

○小出健司 (産総研) 大石修士 (産総研) 横塚将志 (産総研) 阪野貴彦 (産総研)

Kenji Koide (AIST) Shuji Oishi (AIST) Masashi Yokozuka (AIST) Atsuhiko Banno (AIST)

This paper presents a robust sensor localization method on a 3D prior environmental map based on sliding window optimization of tightly coupled LiDAR and IMU constraints. The proposed method directly fuses point cloud registration constraints between consecutive frames, registration constraints with respect to the map point cloud, and preintegrated IMU constraints on a sliding window factor graph. The experimental results show that the proposed method is extremely robust to quick sensor motion and incomplete maps.

Key Words: Localization, Sensor fusion, Point Cloud, IMU

1 緒言

自己位置推定は自律システムにとって重要な要素であり、自動運転車両やサービスロボットなどの多くの応用にとって安定した自己位置推定は不可欠である。近年は安価な三次元距離センサ (e.g., LiDAR や RGBD カメラ) の普及により、特に三次元点群を用いた既知地図上での自己位置推定の研究開発が盛んに行われている。

既存の自己位置推定手法では、NDT や GICP などのスキャンマッチングを現在のセンサ点群と環境地図モデルに対して適用し、その誤差を姿勢空間あるいは直接状態推定フィルタ上で最小化するものが多く提案されている [1, 2, 3]。これらの手法では基本的に一フレームあたり現在のセンサ点群と環境点群のマッチングのみを考えるため、高速な状態推定が可能である。一方で、センサ点群に含まれる幾何特徴が不十分で点群マッチング誤差関数に縮退が起きる状況や、地図に欠損や変化がある場合に推定精度が大きく劣化する。また、より安定した状態推定を行うためにパーティクルフィルタと距離場ベース最適化を組み合わせたモンテカルロ姿勢推定手法 [4] なども提案されているが、距離場ベース最適化が地図欠損領域で不安定になるなどの問題がある。

本研究では、高精度かつ頑強な既知地図上での自己位置推定を実現するため、時間的に前後の点群フレームのマッチングと地図に対するマッチングを同時に考え、さらに IMU 制約を含めた複合コストをもとに最適化ウィンドウ内の複数センサ状態変数の同時最適化を行う。これにより、提案手法は従来手法に対して以下の利点を有する。

1. 前後フレームとのマッチングにより自己運動量の推定が可能となるため、地図が一部あるいは完全に欠損した領域においても安定した状態推定が可能である。
2. 前後フレームとのマッチングと地図とのマッチングは完全に同一の誤差関数で扱われるため、地図内外へのスムーズな遷移が可能である。
3. IMU 制約を含めたウィンドウ最適化によって急激なセンサ運動に対しても極めて頑強に対応することができる。

また、提案手法は特定のセンサに依存する処理を含まないように設計されており、Ouster OS1-64 や Livox Avia のような LiDAR だけでなく Microsoft Azure Kinect などのような RGB-D カメラを含む、任意の Range-IMU センサへの適用が可能となっている。

2 提案手法

提案手法では Fixed-lag smoothing に基づく Range-IMU フェージョンによる移動量推定手法 [5] をベースに、既知地図への点群マッチングを取り込んだファクタグラフ最適化を行う。

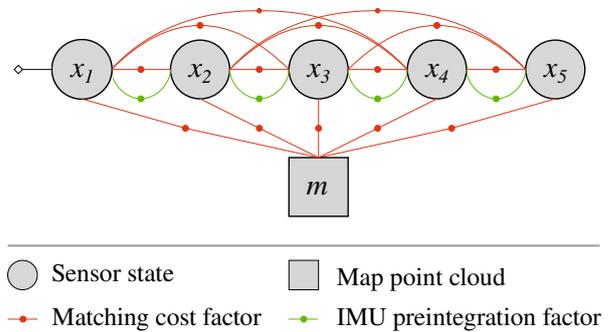


Fig.1: Proposed factor graph. The proposed method directly fuses point cloud registration constraints between consecutive frames, registration constraints with respect to the map point cloud, and IMU constraints on a sliding window factor graph.

Fig. 1 に提案手法の最適化に用いるファクタグラフを示す。提案ファクタグラフは主に、点群間の整合性を評価するマッチングコストファクタと IMU 観測に基づく運動量整合性を評価する IMU ファクタから構成される。マッチングコストファクタには Voxelized GICP [6] を用いる。これは分布対分布マッチングに基づく Generalized ICP [7] をボクセル対応付けを用いて拡張したもので、GICP の精度を保った上で GPU 上での高速なマッチング誤差計算が可能である。自己移動量推定のために現在の点群フレームに対して過去 N フレーム (e.g., 2 フレーム) との間にマッチングコストファクタを生成する。また同時に移動量推定のドリフトを補正するため、現在フレームに対して地図点群との間にもマッチングコストファクタを生成する。IMU 制約には preintegration 手法 [8] を用いることにより、線形化時の再積分処理を省くことで効率的な誤差計算を行う。最適化の目的関数は以下の式で表される。

$$F(\mathcal{X}) = \sum_{\mathbf{x}_i \in \mathcal{X}} \left(\sum_{j=i-2}^{i-1} (f^P(\mathbf{x}_i, \mathbf{x}_j)) \right) + \sum_{\mathbf{x}_i \in \mathcal{X}} (f^P(\mathbf{x}_i, \mathbf{m})) \quad (1)$$

$$+ \sum_{\mathbf{x}_i \in \mathcal{X}} (f^I(\mathbf{x}_{i-1}, \mathbf{x}_i)) + C(\mathcal{X}). \quad (2)$$

ここで、 $\mathcal{X} = [\mathbf{x}_i, \dots, \mathbf{x}_{i+N}]$ は最適化ウィンドウ (e.g., 5 s) 内に存在するセンサ状態変数、 \mathbf{m} は地図点群、 f^P は点群マッ

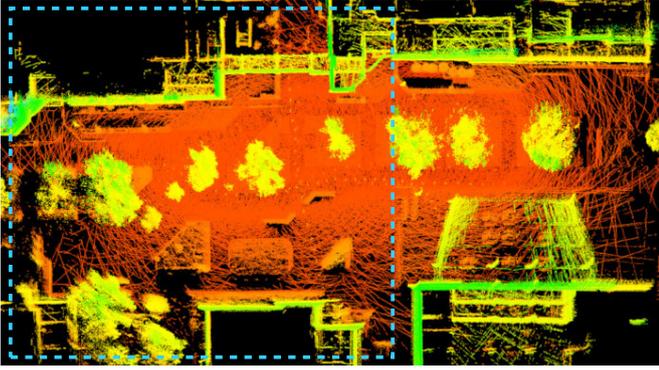


Fig. 2: Experimental environment. To evaluate the robustness to the lack of map points, we removed all the points out of the region indicated by the dashed rectangle.

グ誤差関数, f^I は IMU 誤差関数, C は周辺可された変数・ファクタを補償するための項である。

提案手法では地図に対するマッチングと過去フレームに対するマッチングを完全に同一の誤差関数で扱うため, 地図に大きな欠損がある状況においても, 過去フレームに対するマッチングによる自己運動量推定を基に安定した状態推定が可能である。また, 点群と IMU の誤差関数を直接ファクタグラフ上で統合するため (i.e., タイトカップリング), 急激なセンサの動きに対しても極めて頑強である。

最適化および最適化ウィンドウから出た変数の周辺化にはベイズツリーに基づく効率的な最適化手法である iSAM2 [9] を用いる。実装には GTSAM¹ を用いた。

3 実験

Fig. 2 に実験環境を示す。地図の欠損に対する頑強性を測るため, 破線で囲まれた領域を残し, その他の領域の点群は全て削除したものを環境地図として用いた。比較手法として NDT スキャンマッチングと Unscented Kalman Filter に基づく hdl_localization [10] とパーティクルフィルタと距離場ベース最適化に基づく mcl3d_ros [4] を用いた。Fig. 3 に各手法により推定されたセンサ軌跡を示す。

hdl_localization および mcl3d_ros はそれぞれ, 地図の欠損領域に入った時点で大きな推定誤差が生じていることが確認できる。これは, 両手法ともに状態推定が地図に対するマッチングに大きく依存しているため, 十分なマッチング点が得られない場合に推定が破綻したのだと考えられる。

一方で提案手法は地図に対するマッチングに依存せずに移動量推定を行うことができるため, 地図が欠損した領域に置いても安定したセンサ状態推定が実現できていることが確認できる。また, 欠損領域から元の地点に戻った際には再び地図に対するマッチングが有効となるため, 推定ドリフトを抑制しつつ高精度な移動量推定が実現できている。

4 結言

本研究では, 点群レジストレーション誤差および IMU 誤差のウィンドウ同時最小化による高精度かつ頑強な既知地図での自己位置推定手法を提案した。提案手法では地図に対するマッチングと, 前後フレームのマッチングを同一の誤差関数で扱うことで, 地図の欠損および変化に対して頑強な状態推定を可能とする。実験結果より, 提案手法が地図の欠損した領域に置いても極めて安定した自己位置推定を可能とすることを確認した。

¹<https://gtsam.org/>

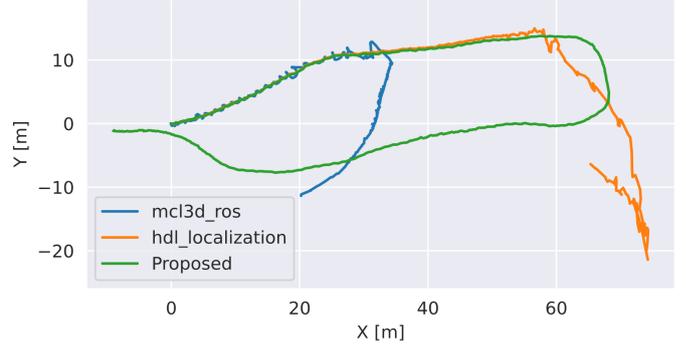


Fig. 3: Estimated trajectories. The existing methods got corrupted when the sensor moved out from the map region. The proposed method successfully estimated the sensor trajectory through the region where points were completely removed.

謝辞

本研究は, 国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) の助成事業の結果得られたものである。

参考文献

- [1] F. Pomerleau, F. Colas, R. Siegwart, and S. Magnenat, “Comparing icp variants on real-world data sets,” *Autonomous Robocs*, no. 34, pp. 133–148, 2013.
- [2] C. Bai, T. Xiao, Y. Chen, H. Wang, F. Zhang, and X. Gao, “Faster-LIO: Lightweight tightly coupled lidar-inertial odometry using parallel sparse incremental voxels,” *IEEE Robotics and Automation Letters*, vol. 7, no. 2, pp. 4861–4868, Apr. 2022.
- [3] R. David and M. A. L., “Lol: Lidar-only odometry and localization in 3d point cloud maps,” in *IEEE International Conference on Robotics and Automation*, 2020, pp. 4379–4385.
- [4] N. Akai, “Efficient solution to 3d-lidar-based monte carlo localization with fusion of measurement model optimization via importance sampling,” 2023.
- [5] K. Koide, M. Yokozuka, S. Oishi, and A. Banno, “Globally consistent and tightly coupled 3d LiDAR inertial mapping,” in *2022 International Conference on Robotics and Automation (ICRA)*. IEEE, may 2022.
- [6] —, “Globally consistent 3d LiDAR mapping with GPU-accelerated GICP matching cost factors,” *IEEE Robotics and Automation Letters*, vol. 6, no. 4, pp. 8591–8598, oct 2021.
- [7] A. Segal, D. Haehnel, and S. Thrun, “Generalized-ICP,” in *Robotics: Science and Systems V*. Robotics: Science and Systems Foundation, jun 2009.
- [8] C. Forster, L. Carlone, F. Dellaert, and D. Scaramuzza, “IMU preintegration on manifold for efficient visual-inertial maximum-a-posteriori estimation,” in *Robotics: Science and Systems XI*. Robotics: Science and Systems Foundation, jul 2015.
- [9] M. Kaess, H. Johannsson, R. Roberts, V. Ila, J. J. Leonard, and F. Dellaert, “iSAM2: Incremental smoothing and mapping using the bayes tree,” *The International Journal of Robotics Research*, vol. 31, no. 2, pp. 216–235, dec 2011.
- [10] K. Koide, J. Miura, and E. Menegatti, “A portable 3d lidar-based system for long-term and wide-area people behavior measurement,” *International Journal of Advanced Robotic Systems*, vol. 16, pp. 1–16, Apr. 2019.