

ワイヤレス距離センサの NLoS 情報を活用した屋内ロボット位置推定手法の開発 — 第3報 ロボット位置とビーコン信号反射面の同時推定 —

Indoor Position Estimation using NLoS Information by Wireless Distance Sensors
— Simultaneous estimation of robot position and beacon signal reflection —

○正 井塚智也 (九大) 正 倉爪 亮 (九大)

Tomoya ITSUKA, Kyushu University, itsuka@irvs.ait.kyushu-u.ac.jp

Ryo KURAZUME, Kyushu University, kurazume@ait.kyushu-u.ac.jp

We develop an indoor robot localization method using wireless distance sensors. To take into account the case where the distance sensor measures the reflected path due to obstacles, we propose a method to estimate the reflected path at the same time and use it for position estimation.

Key Words: Localization, Sensor Fusion, Wireless Distance Sensor

1 はじめに

近年、労働力不足の解決策の1つとしてロボットへの期待が高まっている。特に自律移動ロボットは病院での薬品運搬や荷物の配送など、その可動性を活かしたタスクに応用されている。ロボットにおける自律移動において、核となる技術が位置推定とナビゲーションである。位置推定は地図上でロボットがどこにいるか推定する技術である。ナビゲーションはロボットと周囲の障害物から、目標地点までどのように向かうかを計画する技術である。

位置推定は複数の異なるセンサ情報を融合させるセンサフュージョンによって取り組まれてきた。これはホイールオドメトリや Inertial Measurement Unit (IMU) など、内界センサを利用したオドメトリによる位置推定値を元に、その蓄積誤差を GPS/GNSS や LiDAR など外界センサによる計測より解消するものである。屋内環境では、天井や壁によって GPS が利用できない。そのため、LiDAR によって測定したロボット周囲の環境形状と地図をマッチングさせることによる位置推定がよく用いられる。しかしながら、LiDAR によるマッチング手法は環境形状に依存していることから、長い廊下のような類似形状が連なる環境ではオドメトリの補正が困難である。

ワイヤレス距離センサは、2つのビーコン間の距離をワイヤレスに計測できる。近年 Ultra WideBand (UWB) や超音波による測定技術の向上により、高精度な距離測定が可能となっている。しかしながら、測定対象のビーコン間に障害物がある Non-line-of-sight (NLOS) 状態では、マルチパスなど、測定距離に大きな誤差が載ってしまう。この NLOS 誤差に対しロバスト推定を用いることで、誤差がのっていると思われる測定値の影響をほぼ無くすることが可能である。しかし測定対象のビーコン間に長期間障害物が存在していた場合、そのビーコンから得られた情報がそのまま捨てられてしまい、ビーコンによるオドメトリ補正が途切れてしまう。

本研究ではこの NLOS 誤差に対し、天井や壁などの環境反射面による反射経路も加味し推定する手法の開発に取り組む。本研究の貢献は以下の通りである。

- ホイールオドメトリ、2D-LiDAR、超音波式ワイヤレス距離センサを用いた屋内ロボット位置推定手法の開発に取り組んだ。
- 先行研究 [1, 2, 3] からの改善点として、本手法ではロボット位置推定とビーコン信号反射面の同時推定に取り組む、事前に環境までの距離を与える必要がなくなった。

2 提案手法

本章ではホイールオドメトリ、2D-LiDAR、超音波によるワイヤレス距離センサ（超音波ビーコン）を利用した位置推定手法について述べる。本手法のロボットにはホイールオドメトリおよび 2D-LiDAR が搭載されている。さらにロボットにビーコンを1台、環境側に複数台ビーコンを設置し、ロボットと各ビーコンの距離が一定時間ごとに得られるものとする。ロボット側ビーコン

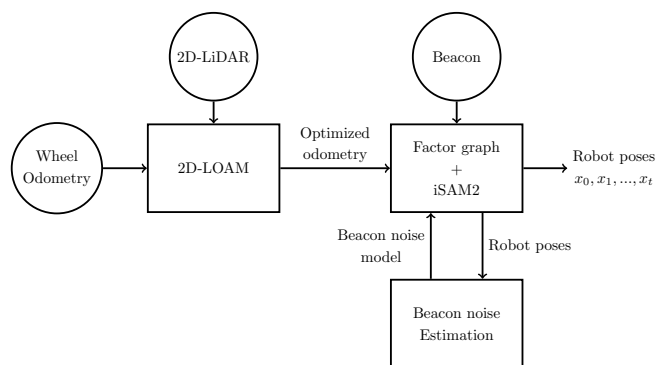


Fig.1 System architecture

と環境側ビーコンの高さは同一平面上であるとし、ロボットの位置と角度は2次元平面上で表せるものとする。

本手法の全体像を図1に示す。まず、2D-LiDARによってホイールオドメトリの補正を行う。その後、補正されたオドメトリとビーコン信号よりファクターグラフを更新し iSAM2 ソルバにより推定を行う。推定後、推定されたロボット姿勢列および各時刻でのビーコン測定値より、各時刻のビーコン残差を計算し、Gaussian Mixture Model による近似を行いビーコン距離ファクタの誤差関数を更新する。

この LiDAR によるオドメトリ補正の後に、他センサをファクターグラフによる融合を行う手法は、3D-LiDAR SLAM である LIO-SAM [4] を参考にした。またファクターグラフでの推定および誤差分布の推定をループ上に繰り返す手法については、文献 [5] を参考にした。

2.1 2D-LiDAR によるホイールオドメトリの補正

LiDAR-Odometry Factor [4] および LOAM [6] を 2D-LiDAR 用に変更しホイールオドメトリの補正を行った。なお、この手法は先行研究 [3] にて実装したものと同一である。

まず滑らかさ特徴 (文献 [6] 5.1 節) より、ある時刻にスキャンした 2D-LiDAR の各点から Edge 点および Planar 点を抽出する。ここで Edge 点は形状的に角の点が抽出され、Planar 点は形状的に滑らかな点が抽出される。

次に、今回得られた特徴点一点一点について、前回スキャンし得られた Edge 点群および Planar 点群との距離を最小化するようなオドメトリを最適化手法を用いて求める。初期値はホイールオドメトリとする。Edge 点については、前回の Edge 点群の最近傍1点との距離を用いる。Planar 点については、前回の Planar 点群より最近傍5点を抽出し、その5点から推定される面と今回の Planar 点との距離を用いる。最適化手法は Gauss-Newton 法を利用した。

推定したオドメトリをファクターグラフの 2D-LiDAR Odometry Factor として用いる。

2.2 ファクターグラフによるポーズグラフ最適化

ファクターグラフは変数ノード、ファクターノード、およびそれらを繋ぐエッジで構成される。変数ノードとして、ロボット各時刻での 2次元平面上の位置・方向、およびビーコンの位置を用いる。

また、本手法で用いるファクターノードは以下の通りである。なお、これらファクタは実装に利用したライブラリ GTSAM [7] にて定義された名前を用いている。

- Prior Factor
ロボットの初期位置・方向および各ビーコン位置の事前分布を表すファクタである。
- Between Factor
ロボットの前回の位置・方向と今回の位置・方向を接続するファクタである。2.1 節にて得られたオドメトリを利用し接続した。
- Range Factor
ビーコンの位置とロボットの位置を接続するファクタである。超音波ビーコンによる測定距離を利用し接続した。

構成されたファクターグラフは非線形最適化問題として、Gauss-Newton 法や Levenberg-Marquardt 法のような反復手法で解を求めることができる。しかしながら、このようなポーズグラフ最適化問題に対しては新たな観測値が得られるたびにグラフが大きくなり、それに伴って推定にかかる時間も増大してしまう。それに対し iSAM2 [8] は更新が必要だと思われる部分のみ推定する、リアルタイムで動作可能な逐次的なソルバであり、LIO-SAM [4] でも利用されている。本手法でもファクターグラフによる各時刻のロボット位置・方向に iSAM2 を利用した。

2.3 環境反射面の推定

NLoS によって生じる NLoS 誤差の中で、マルチパスのため直接経路ではなく反射経路が代わりに計測されてしまった場合を考える。ここでは鏡面反射が 1 度のみ起こったものと仮定する。

ファクターグラフ中のビーコンによる Range Factor について、各時刻のロボット推定位置と、各時刻のビーコン距離測定値から残差 ϵ を計算する。

$$\epsilon = h(X) - z \quad (1)$$

ここで z はビーコンによる測定距離、 $h(X)$ はロボットおよびビーコンの推定位置間の距離である。

残差が一定以上の場合 ($|e| > \epsilon_{th}$ かつ $z > h(X)$)、NLoS による誤差と判断しビーコンの反射像位置と実際の位置までの距離の推定値 s を計算する (図 2)。

$$s = \sqrt{z^2 - h^2(X)} \quad (2)$$

ビーコンごとに計算された s の集合 S について、Gaussian Mixture Model (GMM) による分布の推定を行う。ここで単一のガウシアンではなく GMM としているのは、天井や壁など複数の反射面による反射経路が考えられる場合にも対処できるようにする狙いがある。GMM での推定は文献 [5] と同様に Expectation-Maximization (EM) アルゴリズムにより行っている。

推定した S の GMM による分布を Range Factor の誤差分布に戻す必要がある。これは推定した GMM Θ_s 内の各ガウシアン要素 θ_i^s の重み、平均値 w_i^s, μ_i^s を以下の式で w_i, μ_i に移動させた GMM 要素 $\theta_i \in \Theta$ を計算する。

$$w_i = 0.5 \cdot w_i^s \quad (3)$$

$$\mu_i = h(X) - \sqrt{h^2(X) + (\mu_i^s)^2} \quad (4)$$

この平均値 μ は、各 Range Factor が持つビーコン測定距離 z により移動させる。そのため、時刻が異なる Range Factor ごとに μ は異なる。また通常の直接経路で来た信号も含めるため、重さ $w_0 = 0.5$ 、平均 $\mu_0 = 0$ 、分散 σ^2 の要素 θ_0 も Θ に追加で付け加

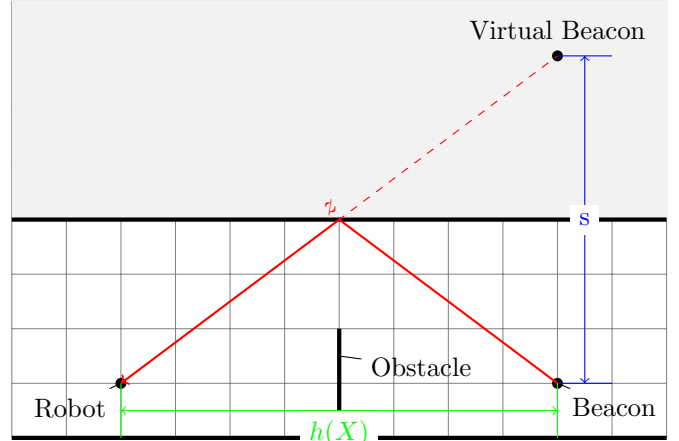


Fig.2 Reflection of a beacon signal

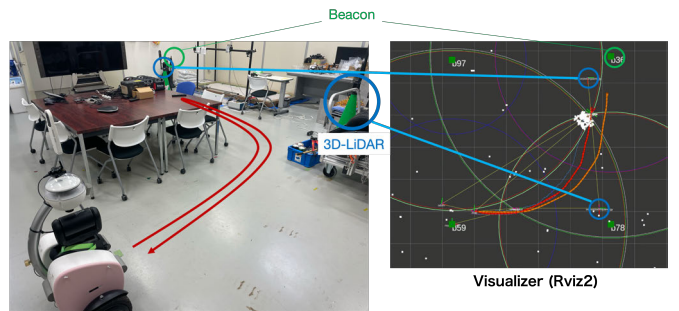


Fig.3 Experimental environment

え、 $\Theta := \{\theta_0, \theta_1, \dots\}$ とする。この Θ をビーコンによる Range Factor の誤差分布として利用する。

本手法では S が一定以上の大きさとなるまでは GMM 推定は行わず、代わりに Tukey-loss によるロバスト誤差関数を Range Factor に適用する。また GMM 内の各ガウシアン要素についてもそれぞれに Tukey-loss を適用し極端な外れ値の影響を無視できるようにした。GMM による誤差分布を Range Factor に適用するためには文献 [9, 10] のような手法があるが、现阶段では本手法上にうまく実装できておらず、今後行う予定である。

3 動作確認実験

提案手法の有効性を検証するため、動作確認実験を行った。まず実験環境 (図 3) にてセンサデータの収集を行った。環境には Marvelmind 社製の超音波ビーコンをおよそ 5m 四方に 4 つ配置し、ロボットには 1 つ取り付けた。環境中にはテーブルや TV などビーコンの妨げとなるものが配置されている。またロボットからはホイールオドメトリおよび 2D-LiDAR のスキャン情報も取得する。ロボット位置の真値として、モーションキャプチャでは障害物でのオクルージョンによる影響が懸念されたため、環境中に 3D-LiDAR を 2 つペアで配置し別途位置推定を行った。これは、キーフレームを設定し、それから差分検知された点群について DBSCAN クラスタリングを行い、ロボットクラスタ内の点群の平均位置を真値とするものである。実験では図 3 の赤線で示した経路を 2 往復させた。以上の条件にて取得した実験データにより、本手法の検証を行った。

まず、NLoS による反射面までの距離 s の分布を正しく推定できているかという点に関して、反射面の GMM 推定値 Θ^s の結果を図 4 に示し考察する。この図はビーコン 4 つそれぞれ推定された GMM Θ_s について重ね合わせて表示したものであり、また、この図中の平均 0 の分布は後から付け加える直接経路による要素 $\theta_0 = \{w_0, \mu_0, \sigma_0^2\}$ を表現した物である。推定の結果、分布が 5.2m 付近に集中している様子が確認された。この環境ではビー

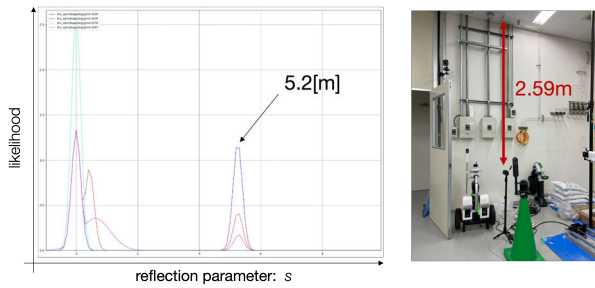


Fig.4 Estimated GMM of a beacon signal reflection \mathcal{S}

	Wheel odom	Robust	Proposed method
ATE	1.266	0.286	0.320

Table 1 Average Trajectory Error(ATE) [m]

コンと天井までの距離が 2.59m であることから、5.2m はおよそその値の 2 倍の数値であるため、天井面での反射像までの距離 s を推定したと考えられる。

次に提案手法を使った場合、位置推定の精度が向上するかについて、環境中ビーコン 4 つを利用した時の推定経路、Average Trajectory Error(ATE) および二乗平均平方根誤差 (RSME) の推移をそれぞれ図 5、表 1、図 6 に示す。手法として、I) ホイールオドメトリのみ (図中では Odometry)、および II) 2D-LiDAR オドメトリ補正 +Range Factor の誤差分布を平均 0 で単一の正規分布とし、Tukey 重みを利用したロバスト推定とする手法 (Tukey)、III) 提案手法 (Tukey+GMM) の 3 つを比較した。提案手法はホイールオドメトリよりも精度は出るものの、ロバスト推定よりも少し精度が劣ってしまう結果となった。これは GMM 誤差分布を利用した推定の実装がうまくいっていないことが原因だと考えられ、今後文献 [9, 10] などの手法の実装に取り組み検証し、追加でさらなる困難な環境でも実験を行う予定である。

4 まとめ

本研究ではワイヤレス距離センサを用いた屋内位置推定において、ビーコン間に障害物が存在することによって生じる NLOS 誤差のうち、マルチパスにより反射経路が得られた場合でも対応できる手法の開発に取り組んだ。

本手法はロボット位置推定とビーコン反射面の推定を交互に繰り返す。こうすることで、事前に天井高など環境壁面の情報を与えることなく、NLoS 時であっても反射経路の利用が可能となる。簡易的な実験では推定した GMM において、天井からと

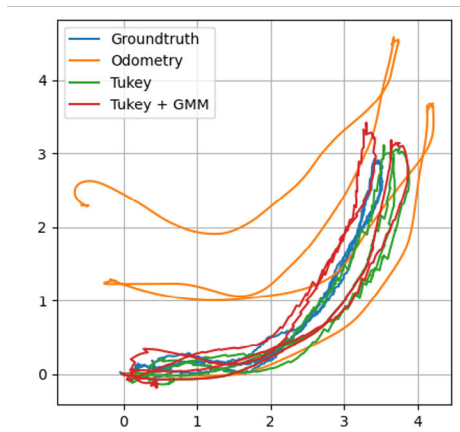


Fig.5 Estimated trajectory

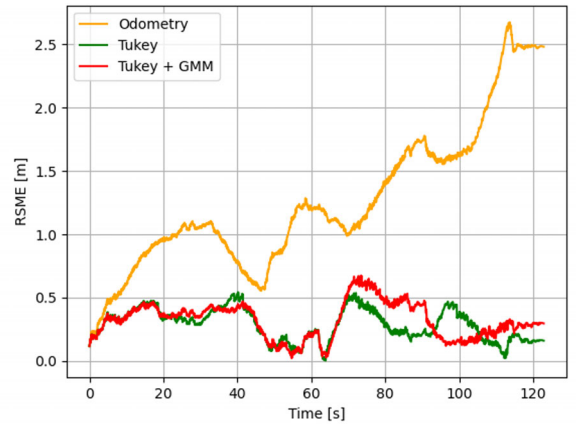


Fig.6 RSME

思われる反射経路が確認できた。

今後の予定として、推定した GMM による誤差分布による正確な位置推定、およびリアルタイム動作可能な高速さを求めて研究を進めていく予定である。

謝辞

本研究の一部は JST 科学技術イノベーション創出に向けた大学フェローシップ創設事業 JPMJFS2132、および JSPS 科研費 JP20H00230 の助成によって実施されました。

参考文献

- [1] 井塚智也, 倉爪亮. ワイヤレス距離センサの nlos 情報を活用した屋内ロボット位置推定手法の開発. 第 40 回日本ロボット学会学術講演会, pp. 2I3-04, 2022.9.5-9.
- [2] Tomoya Itsuka and Ryo Kurazume. Indoor position estimation using nlos information by wireless distance sensors. In *2023 IEEE/SICE International Symposium on System Integration (SII)*, pp. 1-6, 2023.
- [3] 井塚智也, 倉爪亮. ワイヤレス距離センサの nlos 情報を活用した屋内ロボット位置推定手法の開発. 第 40 回日本ロボット学会学術講演会, pp. 2H2-03, 2023.9.12-14.
- [4] Tixiao Shan, et al. LIO-SAM: Tightly-coupled Lidar Inertial Odometry via Smoothing and Mapping. In *IROS 2020*, pp. 5135-5142, October 2020.
- [5] Tim Pfeifer and Peter Protzel. Expectation-Maximization for Adaptive Mixture Models in Graph Optimization. In *2019 International Conference on Robotics and Automation (ICRA)*, pp. 3151-3157, Montreal, QC, Canada, May 2019. IEEE.
- [6] Ji Zhang and Sanjiv Singh. Low-drift and Real-time Lidar Odometry and Mapping. *Autonomous Robots*, Vol. 41, pp. 401-416, February 2017.
- [7] Frank Dellaert and GTSAM Contributors. borglab/gtsam, May 2022.
- [8] Michael Kaess, Hordur Johannsson, Richard Roberts, Viorela Ila, John Leonard, and Frank Dellaert. iSAM2: Incremental smoothing and mapping with fluid relinearization and incremental variable reordering. In *2011 IEEE International Conference on Robotics and Automation*, pp. 3281-3288, May 2011. ISSN: 1050-4729.
- [9] Edwin Olson and Pratik Agarwal. Inference on networks of mixtures for robust robot mapping. *The International Journal of Robotics Research*, Vol. 32, No. 7, pp. 826-840, 2013.
- [10] Tim Pfeifer, Sven Lange, and Peter Protzel. Advancing mixture models for least squares optimization. *IEEE Robotics and Automation Letters*, Vol. 6, No. 2, pp. 3941-3948, 2021.