

事前知識を制約条件として利用した SLAM 手法の比較研究

Comparative study of SLAM techniques that utilize prior knowledge as constraints

桑原 絢一 矢入 健久
KUWABARA Junichi YAIRI Takehisa

東京大学 先端科学技術研究センター
RCAST, The University of Tokyo

In order for robots to move from place to place in an environment, it is necessary to estimate simultaneously its position and position of the landmarks. This is called SLAM and is broadly studied. In SLAM, odometry and observed information are available. In addition to that, some kind of spatial prior knowledge is also available as a constraints. But, not so much study has been done so far to SLAM that utilizes constraints. so, it is valuable to research the kinds of constraints and to compare the techniques that utilizes constraints.

1. はじめに

移動機能を持ち、開いた環境で作業できるロボットとして、移動ロボットがある。これには田畑を耕す農業ロボット、工事現場や建築現場で荷物を運搬し、構造物の組立作業を行う建築ロボットなどが考えられる。また、宇宙深海・原子力施設・災害現場などの「人間が容易に立ち入れない環境」で作業する極限環境作業ロボットも応用例として挙げられる。この極限環境作業ロボットには、作業の信頼性、作業効率、作業安全性といった面から、自動化・遠隔化が強く求められている。極限環境作業ロボット以外の移動ロボットも常に人間が監視や操作をする必要がないように、ロボット自身が判断し行動を決めること、つまり「自律化」が求められている。

自律地図作成の技術は、ロボットを自律化させるための最も基礎的かつ重要な要素技術の一つであり、自律移動ロボットが作業を行う場合、行動計画をおこなうため・走行の安全性を確保する等のために、対象とする作業環境についての空間（環境）モデルである「地図」が必要となる。このような空間モデルは、我々人間にとっても様々な知的活動を行う上で当然欠かせないものである。ところが、惑星探査移動ロボットはもちろん地上移動ロボットも未知環境または部分的既知環境で作業することが求められる。つまり事前に対象とする環境モデルである地図を与えることは困難であり、その環境に応じた観測情報を用いて移動ロボットが自立的に地図を作成することが必要となるからである。

移動ロボットがセンサーなどから得た情報に基づいてどのように地図を獲得するかという問題に関する研究はこれまで盛んに行われてきた。ロボット地図学習法の近年における従来研究では、同時事故位置推定・地図作成問題 (Simultaneous Localization and Mapping:SLAM), つまり外部物体の位置だけでなくロボット自身の位置も同時に推定するという作業を、外部物体との相対距離・角度を画像センサー、レンジセンサーなどによって定量的に計測し、オドメトリを使って移動距離と回転角度を得ることで行う。

従来研究ではロボットは自己位置と環境をセンサー情報とオドメトリを使って推定していく [Thrun 05]. が、環境の推定を行う上で有用な情報はそれだけではなく、様々な空間的事前知

識を用いることが考えられる。例えば、机の上から物が浮いているのはおかしい、A の近くには B はないはず（危険のためなど）、ある範囲にしか存在しないはず、運動が直線の道路上で行われるため方向一定のはず、通常の屋内であれば廊下の壁の幅はほぼ一定であるはず、等である。これらの事前情報は数式としては制約条件として記述することができ、これらを活用して SLAM を行なう研究は存在するが [Beevers 06],[Hyun 06] 数は少なく、まだまだ未開拓である。

本研究では、空間的事前情報を利用する SLAM を行う。制約条件を提示し、数種類の手法を用いてそれぞれに関して効果の比較を行い、推定結果の特徴やどの手法がどの制約条件に適しているのか考察を行う。本研究で行う SLAM の環境とは、計算機上で、制約条件を付加されたランドマークが配置された空間をロボットがランダムに移動するものとする。

2. 従来研究

2.1 ベイジアンフィルターを用いる SLAM

移動ロボットが周囲の環境の地図を作成するためには自己位置を知ることが必要であり、逆に自己位置を知るためには環境の地図が必要である。このようなジレンマを、simultaneous localization and mapping(SLAM) 問題や concurrent mapping and localization(CML) 問題と呼ばれる。近年で最もよく行われるのは Bayesian Filtering を用いることである。Bayesian Filtering は、外部環境を参照することで内的センサによる誤差を修正する手法である。Bayesian Filter を用いる場合、システムにおける環境やセンサ応答などをモデル化する必要があり、性能はシステムモデルの誤差分布がどれだけガウシアンに近くなっているかに依存する。また、移動モデルや観測モデルが非線形である場合には、Extended Kalman Filter や Particle Filter などを用いる。Particle Filter は誤差分布がガウシアンでなくても対応することができる。

2.2 制約条件付き SLAM

制約条件を用いて SLAM を行う例としては [Beevers 06],[Hyun 06] がある。[Beevers 06] では Rao-Blackwellized Particle Filter によって制約のない状態変数を拡張カルマンフィルタによって推定し、制約付きの状態変数をパーティクルによって推定している。[Hyun 06] では掃除ロボットをモデルとして、ジャイロからの位置情報を制約条件として用いている。また、一般的な制約条件の取り扱い法についても

連絡先: 桑原絢一, 東京大学 先端科学技術研究センター 知能工学研究室, 〒153-8904 東京都目黒区駒場 4-6-1, E-mail: kuwabara(at)space.rcast.u-tokyo.ac.jp

触れられている。推定のどのタイミングで制約条件を用いるかという問題に関しては研究は少ない.[Rodriguez-Losada 06]ではシンプルに閾値を用いてどのタイプの制約条件が適用されるべきか決めている。制約条件を用いた一般的な状態推定問題については [Simon 09],[Simon 06] に詳しい。線形や非線形、不等式などの制約条件に対し様々なベジアンフィルタリングアプローチが紹介されている。拡張カルマンフィルター(EKF)を用いた SLAM アルゴリズムの説明をする。本研究ではランドマークの対応関係が既知であるものとする。状態ベクトルはロボットの姿勢とランドマークの座標を共に含む複合状態ベクトルである。すなわち

$$y_t = (x_t \ m_t)^T \quad (1)$$

である。ここで x_t はロボットの位地と向き、 m_t はランドマークの位置である。EKF は移動や観測のモデルが非線形であるときに用いられるアルゴリズムであり、それぞれのモデルを線形近似することによってカルマンフィルターの枠組みを用いる。ロボットの移動と観測がそれぞれ

$$y_t = f(u_t, y_{t-1}) + \underbrace{\varepsilon_t}_{\sim N(0, R_t)} \quad (2)$$

$$z_t = h(y_t) + \underbrace{\delta_t}_{\sim N(0, Q_t)} \quad (3)$$

の式で表現されているとき、これらは一次のテイラー展開によって線形化され、これにより EKF の各更新式は次のように表される

$$\begin{aligned} \bar{\mu}_t &= f(u_t, \mu_{t-1}) \\ \bar{\Sigma}_t &= F_t \Sigma_{t-1} F_t^T + R_t \\ K_t &= \bar{\Sigma}_t H_t^T (H_t \bar{\Sigma}_t H_t^T + Q_t)^{-1} \\ \mu_t &= \bar{\mu}_t + K_t (z_t - h(\bar{\mu}_t)) \\ \Sigma_t &= (I - K_t H_t) \bar{\Sigma}_t \end{aligned} \quad (4)$$

ここでバー付き文字は移動更新後の値を、 μ_t は y_t の期待値、 Σ_t は y_t の共分散、 K_t はカルマンゲインをそれぞれ、 H_t, F_t は h と f の微分をあらわす。本研究では移動モデルを

$$y_t = y_{t-1} + F_x^T \begin{pmatrix} v_t \cos(\theta + \omega_t \Delta t) \\ v_t \sin(\theta + \omega_t \Delta t) \\ \omega_t \Delta t \end{pmatrix} + N(0, R_t) \quad (5)$$

とする。ここで

$$F_x = \begin{pmatrix} 1 & 0 & 0 & 0 & \cdots & 0 \\ 0 & 1 & 0 & 0 & \cdots & 0 \\ 0 & 0 & 1 & \underbrace{0 & \cdots & 0}_{2N \text{ 列}} \end{pmatrix} \quad (6)$$

であり、3次元状態ベクトルを $2N+3$ 次元のベクトルに写像するための行列である。また、観測モデルは

$$z_t = \underbrace{\begin{pmatrix} \sqrt{(m_{j,x} - x)^2 + (m_{j,y} - y)^2} \\ \text{atan2}(m_{j,y} - y, m_{j,x} - x) - \theta \end{pmatrix}}_{h(y_t, j)} + N(0, Q_t) \quad (7)$$

である。

3. 制約条件

ランドマーク間にはあらかじめ何らかの制約が存在する場合が考えられる。例えば、机の上に物は置かれているべきで、宙に浮いていることはない、壁に張り付いている、人工環境であれば廊下は長方形をしていることが多い、同じ方角に並んでいるはず、などである。

これらの制約条件には、等式、不等式、線形、非線形など、様々な分け方がある。正規分布などでは扱いづらい定性的な情報の形で与えられる制約条件も考えられる（物体は時計回りに並んでいる、など）。このような制約条件や RFID のようにある範囲に物体が存在することだけわかるようなセンサーに対しては従来のベジアンフィルタリング拡張アプローチでは十分に対応できない可能性がある。

制約条件は線形の場合 $Dm_t = d$ 、非線形の場合 $g(m_t) = h$ で表される。後者は線形化することによってに前者に帰着できる。本研究では線形の制約条件の例として2つのランドマーク間のベクトルがわかっている場合、非線形の制約条件の例として2つのランドマーク間の距離が等しい場合を考える。すなわち、それぞれ

$$\vec{m}_2 - \vec{m}_1 = \vec{c} \quad (8)$$

$$|\vec{m}_2 - \vec{m}_1|^2 = Const \quad (9)$$

である。

4. 各手法の説明

ここでは制約条件を利用する手法をそれぞれ紹介する。基本は Kalman Filter であり、それぞれの手法はこれを拡張する形で用いられる。

4.1 Perfect Measurements

Perfect Measurements は観測モデルに $Dm_t = d$ を付け加えることによって方程式を拡張し、EKFSLAM に制約条件を取り込む。具体的には観測ベクトルが

$$\begin{bmatrix} z_t \\ d \end{bmatrix} = \begin{bmatrix} H \\ D \end{bmatrix} z_t + \begin{bmatrix} v_t \\ 0 \end{bmatrix} \quad (10)$$

と変化する。 v_t は観測の雑音である。制約条件の雑音が0になっているが、実際の使用上では計算上の問題がでてくることが多いので、ごく小さな誤差をあえて付加する。

4.2 Projection Meethod

Projection Method は制約のない状態で推定された値を制約表面へ投影することによって制約条件を利用する手法である。制約条件付きの Kalman Filter は次のように制約条件付きのコスト関数最小化問題として記述できる。

$$\tilde{\mu}_t = \underset{y_t}{\operatorname{argmin}} (y_t - \tilde{\mu}_t)^T W (y_t - \tilde{\mu}_t) \quad (11)$$

$$Dm_t = d \quad (12)$$

ここで W は正定の重み行列である。これを満たす解は

$$\tilde{\mu}_t = \mu - W^{-1} D^T (D W^{-1} D^T)^{-1} (D \mu_t - d) \quad (13)$$

である。 W は多くの場合推定値の共分散行列の逆行列とする。すなわち $W = (\Sigma_t)^{-1}$ となる。

4.3 Smoothly Constrained Kalman Filter

上記 2 つの手法は制約条件が非線形の場合上手く推定できなくなる場合がある。非線形の場合、線形化の際の誤差が存在するため、結果は近似された制約条件を満たすからである。Smoothly Constrained Kalman Filter (SCKF) は非線形の制約条件に強い Kalman Filter である。SCKF では非線形の制約条件は繰り返し線形化され、不確かさを減少した上で適用される。これは分散 1 の観測を 1 度用いるのは分散 10 の観測を 10 回用いるのと同じであるというアイデアに基づいている。アルゴリズムの詳細は [Simon 02], [Simon 09], [Geeter 07].

4.4 マルコフ連鎖法モンテカルロ (MCMC)

MCMC の概略

マルコフ連鎖モンテカルロ (Markov Chain Monte Carlo : MCMC) 法は、多変量の確率分布からサンプルを得るための一群の手法である [伊庭 05], [Ueta 08]。本研究では EKF による推定結果を事前分布とし、これに制約条件を付け加えたものの物体位置分布の推定を $p(m|c)$ と事後分布として表現する。これは制約条件 c が与えられたときの物体位置分布の確率密度である。ベイズの定理より

$$p(m|c) = \eta p(c|m)p(m) \quad (14)$$

ここで η は確率密度の全区間積分値を 1 とするための正規化定数である。

事後分布 $p(m|z)$ から m のサンプルを得るために、MCMC 法の一つであるメトロポリス・ヘイスティング法 (MH 法) を用いる。事後分布からのサンプリングの手順は以下の通りである。

1. 初期配置 m をランダムに決める
2. m を状態遷移確率 $Q(m', m)$ に従って遷移させた m' を候補とする
3. 確率 $\min(1, r)$ で候補 m' を受理し、状態 m を m' へ遷移させる ($m \leftarrow m'$)
それ以外は m' を棄却し、状態 m に留まる ($m=m$) ここで r は次式で与えられる

$$r = \frac{p(m'|c)Q(m, m')}{p(m|c)Q(m', m)} \quad (15)$$

手順 (2), (3) を十分繰り返すことで近似的に事後分布 $p(m|c)$ に基づく m のサンプリングを行うことができる。生成されたサンプル列 $m^{(1)}, m^{(2)}, \dots, m^{(M)}$ を用いて得られる期待値 \bar{m} とする

$$\bar{m} = \frac{1}{M} \sum_{k=1}^M m^{(k)} \quad (16)$$

確率密度関数の詳細

前節で $p(m|c) = \eta p(c|m)p(m)$ となることを示したが、本研究では $p(c|m), p(m)$ を正規分布と仮定する。 $p(m)$ は EKF によって推定された期待値と共分散を用いる。 $p(c|m)$ は、物体 j と物体 i にベクトル既知の条件がある場合

$$p(c|m) = \frac{1}{2\pi\sqrt{|P|}} \exp\left(-\frac{1}{2}(\hat{v} - c_v)^T P_c^{-1}(\hat{v} - c_v)\right) \quad (17)$$

である。 \hat{v} は推定された制約条件であり、 c_v は制約条件の定ベクトルであり、 P_c は制約の強さをあらわす共分散行列である。距離既知の条件がある場合には MCMC を使用する際には

$$p(c|m) = \frac{1}{2\pi\sqrt{|P|}} \exp\left(-\frac{(\sqrt{(\mu_{j,x} - \mu_{i,x})^2 + (\mu_{j,y} - \mu_{i,y})^2} - c_d)^2}{2\sigma_c^2}\right) \quad (18)$$

c_d は制約条件の距離である。 σ_c は制約条件の強さを表わす共分散である。

5. シミュレーション

本章では各手法の性質を調べるため、実環境を模したシミュレーションを行う。各手法の結果を表示し、考察をする。

5.1 設定

ロボットは時刻 t で回転をした後 1m 先へ進み、ランドマークの観測を行う。これを全ての時間ステップで行い、各アルゴリズムで SLAM を行う。ステップ数は 50 である。全てのランドマークはロボットの姿勢に関わらず観測可能で、データアソシエーションは既知とする。ランドマーク数は 2 つである。ロボットは 10m x 10m の範囲を動き、この外に出ることはない。図では青色は真値、ピンク色は推定値を表わす。紫色の線が見える場合があるが、これは青とピンクが重なったことにより生じる。つまり、真値と推定値が一致していることを示す。また、各手法ごとにベクトル既知の場合と距離既知の場合の推定誤差 ϵ を表 1 に示した。紙面の都合上ロボット的位置に関する表のみをのせるが、位置の推定が成功した場合ランドマークの推定も成功する。 ϵ は以下の式で算出され、シミュレーション 30 回分の平均をとったものをのせる。

$$\epsilon = \sqrt{\frac{\sum_{i=3}^{\text{総 step 数}} (\text{step } i \text{ での位置の真値と推定値の距離})^2}{(\text{総 step 数} - 2)}}$$

5.2 結果

ベクトル既知の条件に対しての結果の図を示す。ベクトル既

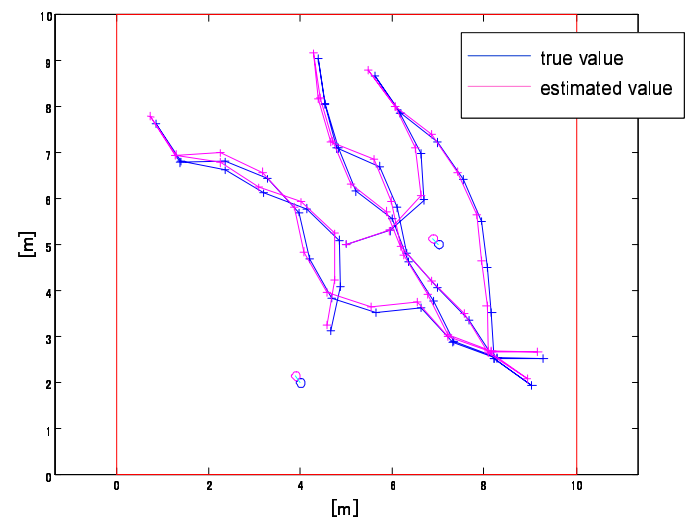


図 1: ベクトル既知での推定結果 (Perfect Measurements)

知は線形かつ強力な制約条件ということもあり、どの手法でも真値と推定値がよく一致する。図 1 は Perfect Measurements によるもので、代表例としてここにのせる。距離既知の条件に対する結果は、スペースの都合上図は省くが、SCKF のときが最も良く推定できる。それは表 1 にあらわれている。次に MCMC のベクトル既知での推定結果を示す。緑色は MCMC を使い推定したロボットの移動軌跡とランドマーク位置である。ピンク色は使わずに推定した結果である。ベクトル既知が強力な条件であるため、MCMC の推定結果は真値と良く一致しており、その一方で制約無しで推定した結果は真値とかなりのズレがある。距離既知の条件では MCMC による推定はほとんどの場合上手くいくともいえないとも言いがたい。ある時刻では良くても別の時刻では悪くなるということがよく起こる。これは距離既知の条件が弱い制約であることに加え、MCMC がロボットの位置推定は行わず、ランドマークの位置推定のみをおこなっていることにも起因していると考えられる。その他の手法ではランドマークの位置とロボットの移動軌跡の両方が影響を受ける。

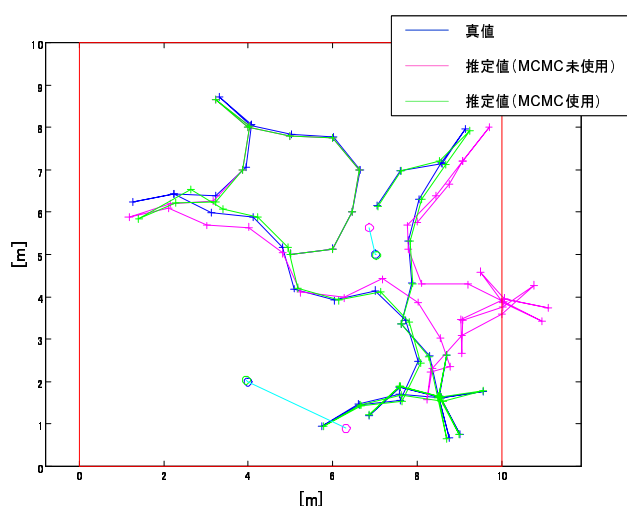


図 2: ベクトル既知での MCMC を用いた推定結果

表 1: 位置に関する推定誤差評価 (単位: m)

	ベクトル既知	距離既知
No Constraints	0.957	
Perfect Measurements	0.184	0.829
Projection Meathod	0.397	0.684
SCKF		0.573
MCMC	0.512	0.914

6. 結論と今後の課題

今回は制約条件の一例としてランドマーク間のベクトルが一定という条件と、ランドマーク間の距離が一定という条件を扱った。両者はそれぞれ線形、非線形という側面を持つ。それぞれの条件に対し、拡張カルマンフィルタに追加する形でそれぞれの手法を適用した。ベクトルが一定という条件は強力な条件であり、追加した場合どの手法でも推定精度を大きく向上させることがわかった。距離一定の条件は、非線形ということもあり、推定精度が多少落ちることがわかった。その中でも最も良

い結果をだすのは Smoothly Constrained Kalman Filter である。

MCMC については距離既知の条件を扱うことはできないがベクトル既知の条件を扱うことはできることがわかった。これによって制約条件の種類によっては MCMC によって取り扱うことができることを示した。

今後の課題としては、制約条件の種類を増やすことが考えられる。制約条件を扱う手法にはまだまだ数々の手法があり、それらについても効果を比較したい。そもそも SLAM を拡張カルマンフィルタで行ったが、Rao-Blackwellized Particle Filter やアンセンテッドカルマンフィルタなどの手法もあり、これらの手法を拡張することも今後の課題である。

参考文献

- [Thrun 05] Thrun, S., Burgard, W. and Fox, D. (2005) : Probabilistic Robotics, MIT Press, 2005.
- [Simon 02] D. Simon and T. Chia. Kalman filtering with state equality constraints. IEEE Transactions on Aerospace and Electronic Systems, 39:128-136,2002
- [Simon 09] Dan Simon Kalman Filtering with State Constraints: A Survey of Linear and Nonlinear Algorithms May 18 2009
- [Simon 06] Dan Simon Optimal State Estimation John Wiley and Sons, Inc., 2006.
- [Beevers 06] K.R. Beevers and W.H. Huang. Inferring and enforcing relative constraints in SLAM. In Workshop on the Algorithmic Foundations of Robotics (WAFR 2006), New York, July 2006.
- [Geeter 07] De Geeter, J., Van Brussel, H., and De Schutter, J.: 'A smoothly constrained Kalman filter', IEEE Transactions on Aerospace and Electronic Systems, 2008, 45, (1), pp.70-84
- [Rodriguez-Losada 06] D. Rodriguez-Losada, F. Matia, A. Jimenez, and R. Galan. Consistency improvement for SLAM - EKF for indoor environments. In IEEE Intl. Conf. on Robotics and Automation, pages 418-423, 2006
- [Hyun 06] Hyun Myung, Hyoung-Ki Lee, Kiwan Choi, Seokwon Bang, YeunBae Kim, Sangryong Kim. Mobile Robot Localization Using a Gyroscope and Constrained Kalman Filter. SICE-ICASE, 2006. International Joint Conference. 18-21 Oct.2006, pp.2098-2103
- [ueta 08] Atsushi Ueta, Takehisa Yairi, Hirofumi Kanazaki, Kazuo Machida: "Map Building by Sequential Estimation of Inter-feature Distances", Lecture Notes in Computer Science, Vol.5351, (PRICAI 2008: Trends in Artificial Intelligence), pp.442-453, 2008
- [伊庭 05] 伊庭幸人: 計算統計: マルコフ連鎖モンテカルロ法の応用、マルコフ連鎖モンテカルロ法の基礎, pp.1-106, 2005.