

複数移動ロボットの相互の観測による自己位置推定

Localization by Co-ovserbing Robots

西村 能輝 堀 浩一
Yoshiteru Nishimura Koichi Hori

東京大学大学院工学系研究科航空宇宙工学専攻
Dept. of Aeronautics and Astronautics, The Univ. of Tokyo

This paper proposes three methods to improve the accuracy of the estimation of robot's self-state by observing other robots mutually. Many methods have been proposed to enable the autonomous robots estimate their states, such as the methods of SLAM (Simultaneous Localization And Mapping). But those methods usually need high precision sensors (e.g. Laser Range Finder) or high computing power. Robots that use low precision sensor and actuator can cover their low performance by using mutual observation of other robots.

In this paper we propose to combine three methods for accurate robot's estimation of their states by using mutual observation of other robots. Each of three methods has advantages and drawbacks. We propose to switch the methods depending on situations.

1. 序論

本論文の目的は、性能の低いロボットが互いに観測し合うことにより、自己の状態の推定の精度を高めることである。ロボットが自律的に移動するためには、プランニング等を行うために自己の状態を推定出来なくてはならない。SLAM(Simultaneous Localization And Mapping)問題の研究により、自律移動ロボットがリアルタイムで自己の状態推定と環境のモデルの取得を行うことが出来るようになっている。しかしながら、それらの手法は高性能なセンサを必要としたり、高い計算能力を要求する。そのため、それらの手法は小型のロボット、特に飛行型のロボットでの使用は積載能力等の関係で難しい。小型のロボットは最初から群で動かすことを想定しているものあり、そうでないものも、一般にコストは低いため複数のロボットを使用しやすい。そういう状況ではロボットはセンサによって他のロボットを観測を行えるだろう。低いセンサやアクチュエータの性能しか持たないロボットであっても、複数のロボットが互いを観測した結果を利用しあうことで、そのセンサ等の性能を補うことのできる可能性が期待できる。

本論文ではロボット同士の観測を利用することにより、自己の状態の推定の精度を高める手法を3種類提案する。3種類の推定手法はそれぞれ、利点・欠点を持つ。3種類の手法を用いることで、それぞれの手法の利点を利用し、欠点を補う。

2. 関連研究

SLAM問題について盛んに研究が行われてきた。多数のセンサのデータを必要としたり、レーザーレンジファインダのような精密なセンサを用いて対象までの十分正確な距離データを得ることできるなどの条件を満たしていればリアルタイムに精密に自己の状態を把握し、かつ、地図作成を行うことができるようになっている。

一方で、そのような高精度なセンサーを用いない研究も行われている。カメラ画像とエンコーダーを利用するものが多く、それらは大別すると2種類に分けられる。カメラ画像からランドマークを見つけ出し、そのデータに対し統計的、確率的な

連絡先: 西村能輝, nishimura@ai.rcast.u-tokyo.ac.jp

手法を適用するもの[10][8]と、見えている画像自体と地図上での位置との対応関係を導こうとするもの[4][7]である。

複数のロボットが協調することで位置推定をする研究もいくつか行われている。例えば、環境を整備しておき、他のロボットからの観測により自己とランドマークがどういった位置関係にあるかを利用するもの[2]、レーザーレンジファインダを用い、他のロボットに対し三角測量を繰り返すもの[5]などがある。

従来の研究では、精度の高い推定のために、高精度のセンサや高い演算能力を必要としている。一方、本論文では性能の低いロボットを複数用いることで自己の状態推定を精度良く行うことが出来る。

3. 提案手法

本論文で3種類の状態推定手法を提案し、それぞれの利点を利用し、欠点を補い合う。それぞれの手法は、複数のロボットが互いを観測した結果を利用して高性能な観測装置等を用いずに、ロボットが単独で行うよりも精度よく自己の状態を推定する。これにより、性能の低いロボット達だけでも自己の状態の推定をより精度良く行うことが可能となる。センサとしてカメラを用い、カメラ画像からランドマークや他のロボットを見つけ、見える方向から自己の状態を推定する。

具体的には、次の3つの手法である。

- 他のロボットをランドマークと見なす
- ロボット全体を一つの系と見なして最尤推定を行う
- ロボット全体を一つの系と見なしフィルタを用いる

自己の状態の推定の精度が上がれば、ロボットの観測の精度も上がるだろう。

各手法の特徴は

他のロボットをランドマークと見なす

新たに発生する通信量を小さくできる。

計算量の増加が小さい

個々のロボットに処理を任せられ、全体を統括する計算機を必要としない

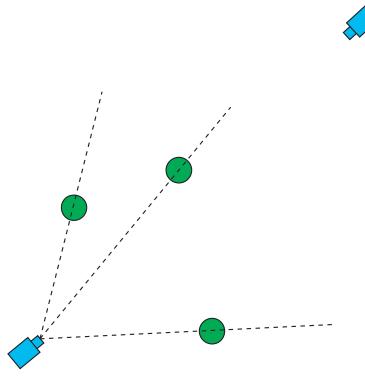


図 1: Estimation using landmark

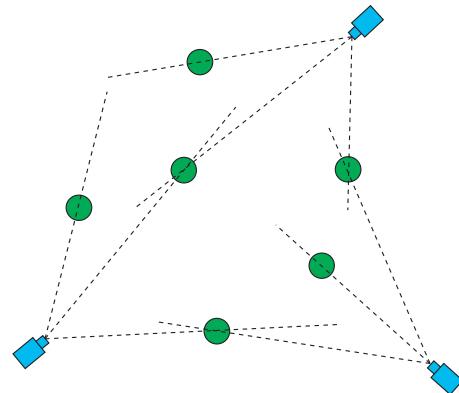


図 3: Estimation using Landmarks

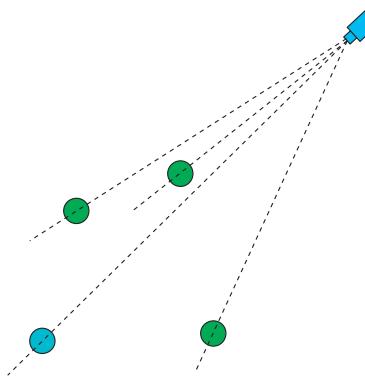


図 2: Estimation by regarding other robots as landmarks

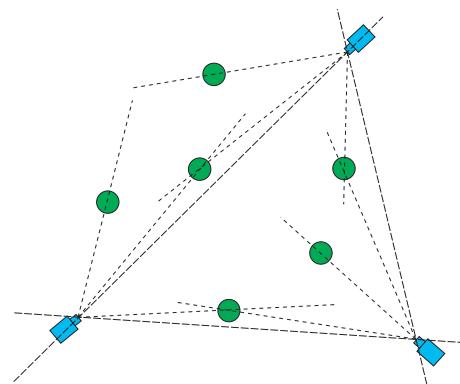


図 4: Maximum Likelihood Estimation for Whole Robots System using whole robot's observations

ロボット全体を一つの系と見なして最尤推定を行う
観測情報等を一ヵ所に集めて処理するため個々のロボットに処理を任せることが出来ない
計算時間がかかる

ロボット全体を一つの系と見なしフィルタを用いる
観測情報等を一ヵ所に集めて処理するため個々のロボットに処理を任せることが出来ない

組み合わせ方としては、通常時はロボット群全体を一つの系と見なしてフィルタを適用することで、オンライン処理により精度良く全体の状態を推定する。ロボット群全体を管理する計算機から遠く離れてしまった等の理由で個々のロボットが自律的に行動する必要がある場合には、他のロボットをランドマークと見なす手法により、状態を推定する。誤差が大きくなってきたらロボット全体を一つの系と見なして最尤推定を行い、誤差をリセットするというものを想定している。

3.1 他のロボットをランドマークと見なす

できるだけ通信量を減らし、また処理ができるだけ個々に任せられる様にしながら、ロボット同士が互いの観測データを利用しあうことで、個別に観測を行った場合よりも精度よい観測を行うことを考える。そこで、次の手順により他のロボットをランドマークと見なすことで自己位置推定の精度向上を行う。自己位置推定にはパーティクルフィルタを用いる。

- (1) ランドマークのみから自己位置推定を行う (Figure 1)。

- (2) 自己位置推定の結果を他のロボットに送信する。
- (3) 位置を送信してきたロボットをランドマークと見なすことで自己位置推定を行う (Figure 2)。

パーティクルフィルタを用いるが、本論文では尤度による重み付き平均で推定値を求め、粒子のリサンプリングは各ステップごとに行った。

この手法の利点は、

- (1) 新たに発生する通信が 2 次元平面上での位置と向き (x, y, θ) のデータをロボットの台数分だけなので、新たに発生する通信量を少なくできる
- (2) ランドマーク数がたかだかロボットの台数分増えるだけと見なせるので、計算量の増加を抑えられる
- (3) 個々のロボットに処理を任せられ、全体を統括する計算機を必要としない

という点である。

尤度関数は

$$\prod_i^n N(\delta_i, \sigma_i)$$

(n:number of landmarks)

3.2 ロボット全体を一つの系と見なして最尤推定を行う

ロボット同士の観測を利用して状態推定の精度を高める。Figure 3 の様にランドマークのみから状態を推定するのではなく、Figure 4 の様に同時に他のロボットを観測した結果を用いる。

具体的な手順は以下の通りである。尤度関数の最大化には Nelder-Mead 法 [6] を用いる。

- (1) ランドマークと他のロボットの見える向きを観測する。
- (2) ロボット群全体の観測値(他のロボット、ランドマークの見た方向)を集める。
- (3) ロボット群全体の観測値を用いて全ロボットの状態を変数として最尤推定を行う。

変数とする状態は次のベクトルのようになる。

$$(x_1, y_1, \theta_1, x_2, y_2, \theta_2, \dots, x_n, y_n, \theta_n)$$

(n:ロボットの台数,x:x 座標,y:y 座標,θ:向き)

また、尤度関数は次の通りである。

$$\prod_i^n N(\delta_i, \sigma_i)$$

Nelder-Mead 法を用いる理由は尤度関数の微分作業が不要となるためである。観測可能範囲にあるロボットやランドマークの数等が変化すると尤度関数も変化する。そのため、微分作業が必要な関数最小化手法では計算のたびに尤度関数を微分しなくてはならず、実装が難しくなる。

3.3 ロボット全体を一つの系と見なしフィルタを用いる

ロボットの系全体を最尤推定をする手法は、各ステップごとに観測結果を用い、系の状態を最尤推定する。そのため、ロボットの移動モデルが活用されないが、Figure4 の様に他のロボットを観測した結果と共にロボットの移動モデルを利用して系の状態を推定したい。設定した条件では、非線形モデルを扱うため Kalman Filter(KF)[9] は、用いることができない。また、非線形モデルで利用されることが多い Extended Kalman Filter(EKF) は、非線形モデルを線形に近似するため精度が必ずしも高くならず、また、前述の通り関数の形が変化するためヤコビアンの導出の必要性は実装を難しくする。そこで Unscented Kalman Filter(UKF)[3] を用いることとする。つまり、ランドマークと他のロボットを観測した結果をまとめ、全てのロボットの状態を合わせたものを変数として UKF の更新を行う。

具体的な手順は全体を最尤推定する手法と似ていて、以下の通りである。

- (1) ランドマークと他のロボットの見える向きを観測する。
- (2) ロボット群全体の観測値(他のロボット、ランドマークの見た方向)を集める。
- (3) ロボット群全体の観測値を用いて全ロボットの状態を変数として UKF により推定を行う。

変数とする状態は次のベクトルのようになる。

$$(x_1, y_1, \theta_1, x_2, y_2, \theta_2, \dots, x_n, y_n, \theta_n)$$

(n:ロボットの台数,x:x 座標,y:y 座標,θ:向き)

UKF は KF と同様に “Time Update” と “Measurement Update” からなる。状態 \mathbf{x}_k の次元を “m” とするロボットの台数を n とすると m は

$$m = 3n$$

システムモデルと観測モデルは、

$$\begin{aligned} \mathbf{x}_{k+1} &= \mathbf{f}_k(\mathbf{x}_k) + \mathbf{w}_k \\ \mathbf{y}_k &= \mathbf{h}_k(\mathbf{x}_k) + \mathbf{v}_k \end{aligned}$$

(\mathbf{w}_k : system noise, \mathbf{v}_k : observation noise)

3.3.1 Time Update

”Time Update” は次の手順でおこなった。

シグマ点へのシステムモデルの適用

$$\left\{ \begin{array}{l} \mathbf{x}_{k+1,0} = \mathbf{f}(\bar{\mathbf{x}}_k) \\ \mathbf{x}_{k+1,i} = \mathbf{f}(\bar{\mathbf{x}}_k + \{\sqrt{(n+\kappa)P_k^{xx}}\}_i) \\ \mathbf{x}_{k+1,i+m} = \mathbf{f}(\bar{\mathbf{x}}_k - \{(\sqrt{(n+\kappa)P_k^{xx}}\}_i) \end{array} \right.$$

κ は Julier[3] に従い $n + \kappa = 3$ とした。

シグマ点の重みは

$$\left\{ \begin{array}{l} W_0 = \frac{\kappa}{m+\kappa} \\ W_i = \frac{1}{2(m+\kappa)} \\ W_{i+m} = \frac{1}{2(m+\kappa)} \end{array} \right.$$

Predicted mean は

$$\hat{\mathbf{x}}_{k+1} = \sum_{i=0}^{2m} W_i \mathbf{x}_{k+1,i}$$

Predicted covariance は

$$\hat{\mathbf{P}}_{k+1} = \sum_{i=0}^{2m} W_i (\mathbf{x}_{k+1,i} - \hat{\mathbf{x}}_{k+1})(\mathbf{x}_{k+1,i} - \hat{\mathbf{x}}_{k+1})^T$$

3.3.2 Measurement Update

”Measurement Update” は次の手順で行った。

それぞれの Prediction point を Observation model からもとめる。

$$\mathbf{Z}_{k+1,i} = \mathbf{h}(\mathbf{x}_{k+1,i})$$

Predicted observation は

$$\hat{\mathbf{z}}_{k+1} = \sum_{i=0}^{2m} W_i \mathbf{Z}_{k+1,i}$$

Innovation covariance は

$$\mathbf{P}_{k+1}^{zz} = \sum_{i=0}^{2m} W_i (\mathbf{Z}_{k+1,i} - \hat{\mathbf{z}}_{k+1})(\mathbf{Z}_{k+1,i} - \hat{\mathbf{z}}_{k+1})^T + \mathbf{R}_{k+1}$$

(\mathbf{R}_{k+1} : observation noise matrix)

Cross correlation matrix は

$$\mathbf{P}_{k+1}^{xz} = \sum_{i=0}^{2m} W_i (\mathbf{x}_{k+1,i} - \hat{\mathbf{x}}_{k+1})(\mathbf{Z}_{k+1,i} - \hat{\mathbf{z}}_{k+1})^T$$

Kalman gain は

$$\mathbf{K}_{k+1} = \mathbf{P}_{k+1}^{xz} (\mathbf{P}_{k+1}^{zz})^{-1}$$

Error covariance の更新は

$$\mathbf{P}_{k+1}^{xx} = \hat{\mathbf{P}}_{k+1} - \mathbf{K}_{k+1} \mathbf{P}_{k+1}^{zz} \mathbf{K}_{k+1}^T$$

推定値の更新

$$\bar{\mathbf{x}}_{k+1} = \hat{\mathbf{x}}_{k+1} + \mathbf{K}_{k+1} (\mathbf{z}_{k+1} - \hat{\mathbf{z}}_{k+1})$$

(\mathbf{z}_{k+1} : observation vector)

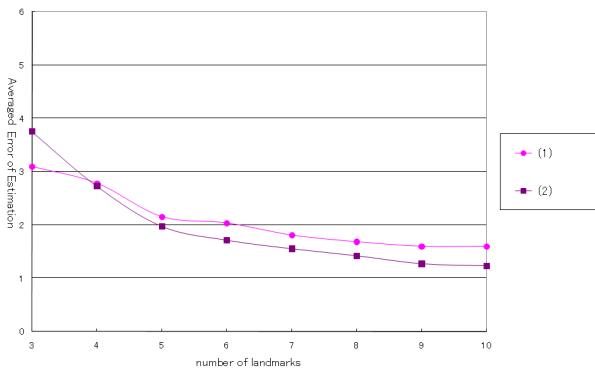


図 5: error of localization

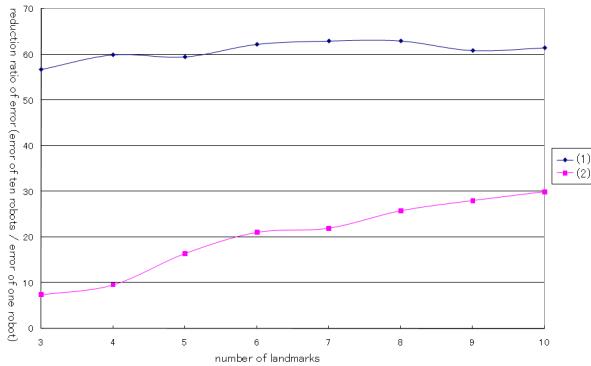


図 6: reduction ratio of error (error of ten robots / error of one robot)

4. シミュレーション

地図を与え、提案した3手法で、自己位置推定を行った。UKFについては設定条件が違うため載せていないが、おおむね同じような結果である。ロボットが5台の場合で同時に観測されるランドマークの数を変化させて自己位置推定誤差のデータをとったものがFigure 5である。(1)が他のロボットをランドマークと見なす手法で(2)が系全体を最尤推定する手法の結果である。

ロボットが1台と10台の場合で自己位置推定誤差のデータの比をとったものがFigure 6である。(1)が他のロボットをランドマークと見なす手法で(2)が系全体を最尤推定する手法の結果である。他のロボットをランドマークと見なす手法では誤差がも1/3から1/2程度となっている。系全体を最尤推定する手法では1/10から1/3程度となっている。全体的に精度は良くなっているが、系全体を最尤推定する手法の特に同時に観測されるランドマーク数が少ない場合に性能の向上が顕著である。この差は、他のロボットをランドマークと見なす手法では地図上の位置に誤差のあるランドマークが他のロボットの台数分増えることと同じなのに対し、全体を最尤推定する手法では、他のロボットの視線を通じて誤差はあるがランドマークの数がロボットの台数倍になることと同じであるとの差が出ているのだと考えられる。

5. 結論

本稿では我々は十分な精度のないセンサーとアクチュエータを搭載したロボットが、お互いに観測し合うことで正確な状態の推定を行う手法を提案した。

提案した3つの手法でロボットが1台の時より正確に推定を行うことは達成できた。ただ、現在は観測するときにロボットが停止していないといけないという問題がある。今後はその課題を取り組む予定である。また、ロボット群の移動を制御することにより正確な状態推定を行えるようにするつもりである。

参考文献

- [1] T. Bakch and L. E. Parker. *Robot Teams*. A K Peters, 2002.
- [2] K. Hosoi, R. Nitta, Y. Yabiku, and M. Sugimoto. A blimp robot that interacts with humans. In *AFO'05 in Hakodate*, 2005. (in Japanese).
- [3] S. J. Julier and J. K. Urlmann. A new extension of the kalman filter to nonlinear systems. In *Proc. AeroSense: 11th Int. Symp. Aerospace/Defense Sensing*, pages 182–193, 1997. Simulation and Controls.
- [4] N. Karlsson, E. D. Bernardo, J. Ostrowski, L. Goncalves, P. Pirjanian, and M. E. Munich. The vslam algorithm for robust localization and mapping. In *Proceedings of the International Conference on Robotics and Automation*, 2005.
- [5] R. Kurazume and S. Nagata. Cooperative positioning with multiple robots. In *Proc. IEEE Int. Conf. on Robotics and Automation*, 1994.
- [6] J. Nelder and R. Mead. A simplex method for function minimization. *Computer Journal*, 7(4):308–313, 1965.
- [7] K. Nishizuka and K. Machida. Map construction from inaccurate distance information on planetary surface using multidimensional scaling. Master's thesis, University of Tokyo, 2005.
- [8] T. Sogo, H. Ishiguro, and T. Ishida. Acquisition and propagation of spatial constraints based on qualitative information. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2(3), 2001.
- [9] G. Welch and G. Bishop. An introduction to the kalman filter. University of North Carolina at Chapel Hill, Chapel Hill, NC, 1995.
- [10] T. Yairi, K. Hori, and K. Hirama. Qualitative map learning based on covisibility of objects. *IEEE Transaction on Systems*, 35(4), 2005.