

次元削減を用いた地図作成に関する実験的研究

Experimental Study on Mapping by Dimensionality Reduction

中村 翔*¹ 矢入 健久*²
 Sho Nakamura Takehisa Yairi

*¹東京大学大学院工学系研究科

School of Engineering, The University of Tokyo

*²東京大学先端科学技術研究センター

Research Center for Advanced Science and Technology, The University of Tokyo

Previous researches using Simultaneous Localization and Mapping (SLAM) technology based on Bayesian filtering have suggested methods of making environmental map by robots. However, we can not use these approaches when measurement model and movement model of system are unavailable. In this paper, we propose dimensionality reduction approach instead of Bayesian filtering approach to solve this problem. In experimental study, we conduct real robot experiments to present applicability of proposed method to real environment.

1. 研究の背景と目的

1.1 従来の地図作成

移動ロボットが空間を移動する際、効率的に空間を移動するためには同じところを2度通らないなどの工夫が必要である。これを実現する方法として挙げられるのが、ロボットが地図を持つことである。地図があらかじめ与えられている環境では問題がないが、そうではない状況下においては、ロボット自身が探査の間に地図を構築する必要がある。この場合、ロボットは地図の作成と、地図上の自己位置推定の2つを同時に達成せねばならない。こうした問題は Simultaneously Localization and Mapping (SLAM) と呼ばれる。

この問題に対して従来からさかんに研究されてきたのが、ベイジアンフィルタを用いた手法である。具体的には Extended Kalman Filter (EKF) や粒子フィルタなどの手法がある。これらは、 x を発見された地図上の特徴点、 r をロボットの姿勢、 y を観測データ、 u を入力、 e を誤差、 t を時刻、 i を特徴点の ID としたとき、以下の動作モデルと計測モデルを必要とする。

$$\begin{aligned} r_{t+1} &= f(r_t, u_t) + e_t^f \\ y_{t,i} &= g(r_t, x_i) + e_t^g \end{aligned} \quad (1)$$

1.2 モデルがない場合の地図作成

(1) 式で表されるモデルが得られないケースについて考えてみたい。例えば、ロボットではなく人がカメラを持って空間上を動き回り部屋の地図を作成するようなケースにおいては、加速度センサやジャイロを持たない限り動作モデルがわからないため、従来の手法によって地図を作成することができない。また、たとえ厳密なモデルを持つロボットであっても、カメラの故障により想定外のセンサだけを使って探査を行う必要に迫られたような場合、計測モデルを用いることができない。このようなケースにおいては、厳密な地図を作成することは難しいが、その場所固有の情報が得られる限り、別のアプローチを行えばより曖昧に空間を表現した地図を得られることが期待で

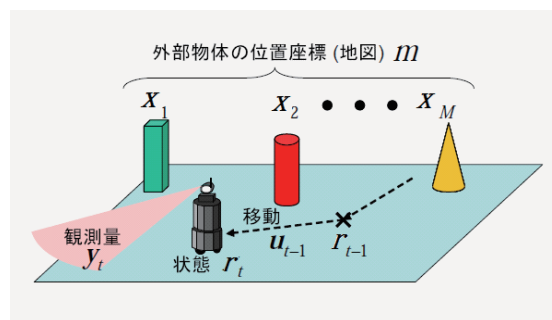


図 1: 問題設定

きる。

上記のような厳密な計測モデル・動作モデルが与えられない状況下において、観測者が移動することによって空間の形状を把握するための曖昧な地図の作成を行うために、次元削減や回帰学習に基づく手法が考えられる [Pan 07]。こうした手法は、ロボットによる観測履歴を、各時刻における全特徴に関する観測を行ベクトル、各特徴に関する全時刻の観測を列ベクトルとするようなマトリクスとして表すことができる。

しかし、従来の手法ではこのマトリクスに大規模な欠損値が存在してしまうため、地図の作成が困難であった。本論文ではそれを解決する手法を導入し、環境の地図を得ることを目指す。

2. 共埋め込み法

「共埋め込み法」は矢入が考案した次元削減手法であり、従来の SLAM に行ってきた地図作成と、移動軌跡の推定である自己位置推定を分けて扱う。まず地図作成を行ってから移動軌跡の推定を行う。本手法の特長として、計測モデルや動作モデルをあらかじめ必要としないことが挙げられる。これによって、様々な種類のセンサに対応することができる。また、もう一つの特徴として高次元の観測空間上の低次元の多様体を次元削減によって展開することで、地図や移動軌跡が手に入る。そ




図 2: 共埋め込み法概念図

のために以下の 2 つの仮定を置いている。(1) 観測データは、局所的には地図上の特徴点の座標を線形変換することで得られる。また、その変換は観測者の姿勢のみによって決定される。(2) 制御入力 u は並進運動と回転運動の 2 成分に分けられる。本手法では上記のような特長を実現するために、いくつかの制限が存在する。一つはオフライン手法であるために、観測者が全ての観測を終えた後に地図を作成するという手順になることである。もう一つは、得られる地図や自己位置の履歴において、回転やスケール変化の自由度をなくすため、部分的にあらかじめ位置がわかっている地図上の特徴点 (ランドマーク) を与える必要があり、また、部分的に自己位置を参照できる必要がある。部分的に求めたい変数の解がわかっているという点で、これらのデータは半教師あり学習の枠組みに当てはまる。

2.1 問題設定

図 1 に表されるように、観測者 (ロボットや人) の t ステップ目 ($t = 1, \dots, M$) における姿勢を r_t で表す。 r_t は位置と方向の成分を持つベクトルである。また、地図は特徴ベースで表現される。すなわち、地図上の建物のような目立ったところを観測することによって全体の地図を構築する。この i 番目 ($i = 1, \dots, N$) の特徴を x_i で表す。本論文ではデータアソシエーションの問題を考慮せず、観測された特徴は識別可能と仮定し、時刻 t における特徴 i の観測値を $y_{t,i}$ と表す。

ラベル付けされた観測者の位置は r_t^* 、特徴は x_i^* で表す。また、ラベルの有無はそれぞれ 1, 0 の 2 値をとる δ_t^r, δ_i^x で定義する。

以上の設定の元で、共埋め込み法の仮定を式で示す。前述のロボットによる局所的な観測データは特徴点の線形変換で表されるため、射影行列 $G(r_t)$ を用いて、

$$g(r_t, x_i) \approx G(r_t)[x_i^\top, 1]^\top \quad (2)$$

と書ける。また、移動モデルが並進と回転に分離できることは、以下のように表される。

$$\text{If } u_t^p \approx 0 \quad \text{then } \|p_{t+1} - p_t\| \approx 0 \quad (3)$$

$$\text{If } u_t^\theta \approx 0 \quad \text{then } \|\theta_{t+1} - \theta_t\| \approx 0 \quad (4)$$

2.2 地図作成

前述のように、共埋め込み法では地図作成を行った後に移動軌跡推定を行う。ここではまず、地図作成について述べる。

特徴点から観測データへの変換が線形であることを利用して、 $\hat{x}_{t,i}$ を特徴の推定値とすると、変換行列 T_t を導入して、

$$\hat{x}_{t,i} = T(r_t)[y_{t,i}^\top, 1]^\top = T_t z_{t,i} \quad (5)$$

と書くことができる。ここで、ある時刻での $\hat{x}_{t,i}$ は別の時刻

での $\hat{x}_{t',i}$ に近いはずであるという考えを用いると、コスト関数は

$$\Phi_{aln} = \frac{1}{2} \sum_{i=1}^N \sum_{t \neq t'} \tilde{q}_{t,i} \tilde{q}_{t',i} \|\hat{x}_{t,i} - \hat{x}_{t',i}\|^2 \quad (6)$$

と書ける。ここで、 $\tilde{q}_{t,i}$ は、時刻 t に i 番目の特徴が観測されれば 1、されなければ 0 の 2 値をとる。これによって、欠損している観測値は自動的に無視される。これを $v_i = [\tilde{q}_{1,i} z_{1,i}^\top, \dots, \tilde{q}_{M,i} z_{M,i}^\top]$ 、 $V = [v_1^\top, \dots, v_N^\top]^\top$ 、 $D_t = \sum_{i=1}^N \tilde{q}_{t,i} z_{t,i} z_{t,i}^\top$ 、 $D = \text{diag}(D_1, \dots, D_M)$ 、 $T = [T_1, \dots, T_M]^\top$ を用いて行列形式で書くと、

$$\Phi_{aln}(T) = \text{Tr}(T^\top (D - V^\top V) T) \quad (7)$$

と表される。

さらに、与えられたラベル付きデータに近づけるという意味でコスト関数

$$\Phi_{xlb} = \sum_{i=1}^N \delta_i^x \|\hat{x}_i - x_i^*\|^2 \quad (8)$$

を用意することができる。ここで、

$$\hat{x}_i = \frac{\sum_{t=1}^M q_{t,i} \hat{x}_{t,i}}{\sum_{t=1}^M q_{t,i}} = \sum_{t=1}^M \tilde{q}_{t,i} \hat{x}_{t,i} \quad (9)$$

である。同様に $X^* = [x_1^*, \dots, x_N^*]^\top$ 、 $J_x = \text{diag}(\delta_1^x, \dots, \delta_N^x)$ を使って行列形式で書くと、

$$\Phi_{xlb}(T) = \text{Tr}((VT - X^*)^\top J_x (VT - X^*)) \quad (10)$$

となる。

(6) 式と (8) 式から、パラメータ α を導入して、 $\Phi_{map}(T) = \Phi_{aln} + \alpha \Phi_{xlb}$ が得られる。ここで、(7) 式と (10) 式において、 $T = [T_1, \dots, T_M]^\top$ について微分したものを 0 とすることによって、 T の推定値は

$$\hat{T} = \{D + V^\top (\alpha J_x - I) V\}^{-1} (\alpha V^\top J_x X^*) \quad (11)$$

と得られる。さらに (5) 式と $\hat{X} = [\hat{x}_1, \dots, \hat{x}_N]^\top$ から導出される $\hat{X} = V \hat{T}$ に代入することによって、特徴の推定値が得られる。

2.3 移動軌跡推定

共埋め込み法によって観測者の自己位置推定、すなわち観測者が動き回った経路を計算する方法について述べる。地図作成フェイズの副産物として r_t のみによって決まる変換行列 T が得られた。前述のように、入力には並進と回転の 2 成分に分解されるが、これらは T の線形変換 H で得られると考えられ、それぞれ、

$$\begin{aligned} \hat{p}_t &= H_p \text{vec}(\hat{T}_t) \\ [\cos(\hat{\theta}_t), \sin(\hat{\theta}_t)]^\top &= H_\theta \text{vec}(\hat{T}_t) \end{aligned} \quad (12)$$

と表せる。ここで、 $\text{vec}(\hat{T}_t)$ は \hat{T}_t を列ベクトルに変形したものである。次に、地図作成と同様に H_p 、 H_θ を求めるためのコスト関数を用意する。 p および θ に関して計算方法は基本的に




図 3: 地図の設定

同じなので、以下では p のみについて示す。

$$\Psi_p = \sum_{s < t} w_{s,t}^p \|\hat{p}_s - \hat{p}_t\|^2 + \beta \sum_{t=1}^M \delta_t^r \|\mathbf{p}_t^* - \hat{p}_t\|^2 \quad (13)$$

第 1 項が、1 つ前のステップにおいて入力 0 ならば、とりうる値は同じであること、第 2 項が、ラベルデータに近づけることをそれぞれ意味する。ここで、 $w_{s,t}^p$ は

$$w_{s,t}^p = \begin{cases} 1 & (t = s + 1 \wedge u_s^p \approx 0) \\ 0 & (\text{otherwise}) \end{cases} \quad (14)$$

である。これを行列形式で書くと、 $\hat{\mathbf{P}} \equiv [\hat{p}_1, \dots, \hat{p}_M]^\top$, $\mathbf{P}^* \equiv [p_1^*, \dots, p_M^*]^\top$, $\mathbf{J}_r \equiv \text{diag}(\delta_1^r, \dots, \delta_M^r)$, $\mathbf{T}^\dagger \equiv [\text{vec}(\hat{\mathbf{T}}_1), \dots, \text{vec}(\hat{\mathbf{T}}_M)]^\top$, $\mathbf{D}_p \equiv \text{diag}(\sum_{s=1}^M w_{s,1}^p, \dots, \sum_{s=1}^M w_{s,M}^p)$, $\mathbf{L}_p \equiv \mathbf{D}_p - \mathbf{W}_p$, を用いて、

$$\Psi_p = \text{Tr}[(\mathbf{P}^* - \mathbf{T}^\dagger \mathbf{H}_p^\top)^\top \mathbf{J}_r (\mathbf{P}^* - \mathbf{T}^\dagger \mathbf{H}_p^\top)] + \beta \cdot \text{Tr}[\mathbf{H}_p (\mathbf{T}^\dagger)^\top \mathbf{L}_p \mathbf{T}^\dagger \mathbf{H}_p^\top] \quad (15)$$

となる。これを \mathbf{H}_p について微分し、得られた

$$\hat{\mathbf{H}}_p^\top = ((\mathbf{T}^\dagger)^\top (\mathbf{J}_r + \beta \mathbf{L}_p) \mathbf{T}^\dagger)^{-1} (\mathbf{T}^\dagger)^\top \mathbf{J}_r \mathbf{P}^* \quad (16)$$

を、(12) 式に代入することによって、目的の推定値 \hat{p}_t が得られる。

3. シミュレーション

実験を行う前に、実環境を模擬したシミュレーションを行った。また、本論文においてはこれ以降、移動履歴の計算は行わず、地図の作成のみを行う。

図 3 が環境の様子を示したものである。このシミュレーションでは、環境は 20m 四方の正方形の領域であり、200 個の特徴 (赤丸と青丸) を含んでいる ($N = 200$)。地図作成での結果の評価を分かりやすくするため、このうちの 100 個の特徴 $\{x_1, \dots, x_{100}\}$ (赤丸) が “ABCD” という文字列を形成するように配置を行った。また、特徴位置に関するラベル情報として、11 個のランドマーク特徴 (青い四角) を定め、その位置 x_i^* が事前に分かるとした。ロボットは正面に 180 度の視野を持ち、8m 以内の範囲にある特徴を観測できるとした。方向のみがわかるセンサ、距離のみがわかるセンサの 2 種類を想定してシミュレーションを行った。また、それぞれにガウシアンノ

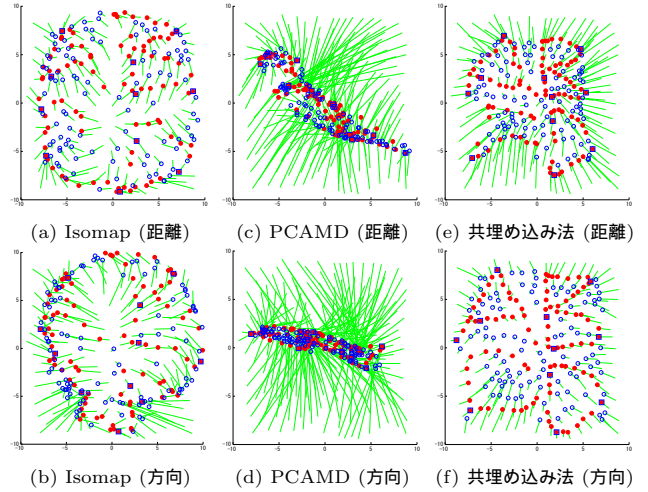


図 4: シミュレーション結果




図 5: ARToolkitPlus のマーカー




図 6: 実験風景

イズを加えている。

ここでは、比較手法として、次元削減法である Isomap[Tenenbaum 00] と、PCAMD[Okatani 07] についてもシミュレーションを実施した。これらは教師なしの次元削減法なので、ラベル付けした特徴について最小二乗法により最適な線形変換を適用した。

図 4 がシミュレーションの結果であり、緑の線が真値からの誤差である。距離センサ、方向センサを模擬したどちらの場合においても、共埋め込み法が最良の結果を示しているのがわかる。

4. 実験

4.1 実験 1

研究室環境において実験を行った。ロボットは、MobileRobots 社の Pioneer 3-DX を用いた (図 6)。本論文ではこのロボットを手動で無線を使ってコントロールした。移動方法は 100mm/sec の直進と、5deg/sec の左右回転運動のみとした。ロボットに単眼の Web カメラであるサンワサプライの CMS-V20 を図 6 のように搭載し、640*480dot の画像を 10fps で取得した。

本論文においては特徴点はデータアソシエーションを考慮しないため、拡張現実の分野で利用される ARToolkitPlus を利用した。ARToolkitPlus のマーカーは正方形の平面に白と黒のグリッドから成り、それぞれのマーカーが個別の ID を持つ。ARToolkitPlus を使うとマーカーを画像から読み取ることによって距離計算ができるが、今回は単純に ID と、マーカー中心点の画像上での水平方向の位置のみを取得した。ロボットは、パネ

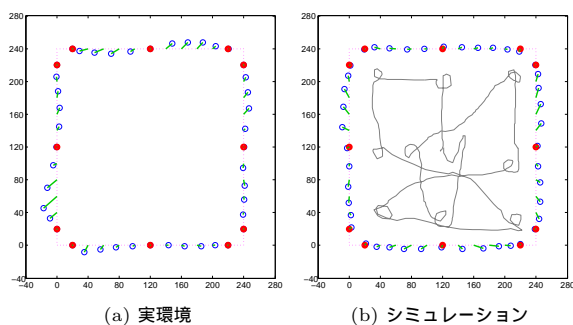


図 7: [実験 1] 実験結果

ルで囲われた 240cmx240cm の正方形の部屋の中をランダムに走行する．正方形の各辺にはそれぞれ 11 個，全 44 個のマーカーを 20cm 間隔で設置し，鉛直方向には床から 20,40,60cm の位置にランダムに配置した．また，ランドマークとして 12 個のマーカー位置を既知の値として我々の手法に与えた．

図 7 の左側が実験結果で，比較のため，Web カメラに近い視野角で実際のロボットの動きに近い軌跡でシミュレーションして得られた結果を図の右側に配置した．マゼンタの点線がパネルの外形の真値を示す．また，赤丸はランドマークとして用いられているマーカーである．青丸が推定値を示す．緑色の線が実際の位置からの誤差を示している．シミュレーションにおいては，ロボットの軌跡の真値がわかっているので灰色の線で示した．推定値が部屋の外形にそっていることがわかる．

4.2 実験 2

実験 1 においては特徴点を全て ARToolKitPlus のマーカーで示したが，実環境においてはマーカーの設置範囲に限られる状況が考えられる．そうした場合には，カメラ画像の処理によりマーカーがない位置においても特徴を認識できることが望まれる．ここでは，従来の SLAM 研究 [Folkesson 07] において広く使われてきた Scale-Invariant Feature Transform (SIFT) を導入した．SIFT は，画像の回転やスケール変化，照明変化に強いといった特長を持つ．特徴の ID を識別するために，画像毎の特徴同士のマッチングも行った．研究室の一角に，ラベルデータであるランドマークとして 17 個の AR マーカーを貼り付け，これらの 2 次元平面での位置をあらかじめ計測して与えた．実験 2 ではロボットではなく人間が Web カメラを持って研究室を動き回ることによって動画画像を取得し，解析を行った．具体的には AR マーカーの画像上での座標取得および，一般の特徴点として SIFT 特徴量の取得，およびマッチングを行った．

図 8 に結果を示す．赤丸がランドマーク，青丸が SIFT を用いて共埋め込み法によって得られた推定点である．与えられたランドマークを中心として周辺に SIFT 特徴点が集まっている．特徴点の密度が位置によって異なるが，部屋の中の物の配置による影響が大きいこと由来すると考えられる．

5. 結論

ベイジアンフィルタによる手法が一般的な SLAM において，本論文では次元削減の手法を用いることで，モデルを持たない曖昧な環境下での地図の作成方法について示した．実環境に近い状況を想定したシミュレーション結果が得ることができ，また実験 1 において AR マーカーを利用することで，シミュレーションと同様の推定結果が得られたため，本手法が実環境にも応用可能であることが示された．

今後 SIFT を用いた実験については精度評価を実施し，精

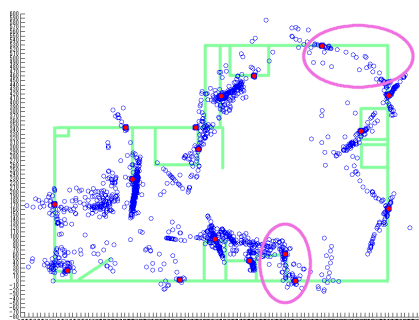


図 8: [実験 2] SIFT を用いた実験

度の改善をはかることができると考える．また，カメラ以外のセンサーについても共埋め込み法の適用法を探っていくことが今後の課題として挙げられる．

参考文献

- [Pan 07] Pan, J., Yang, Q.: Co-localization from labeled and unlabeled data using graph Laplacian. In: Proceedings of IJCAI-07. (2007) 2166–2171
- [矢入 07] 矢入健久.: 観測履歴の次元削減による地図獲得法, 第 21 回人工知能学会全国大会 (2007)
- [藤吉 07] 藤吉弘亘.: Gradient ベースの特徴抽出 - SIFT と HOG -, 情報処理学会研究報告 CVIM 160, pp. 211–224 (2007)
- [山田 08] 山田達也.: 屋内小型飛行船による自己位置姿勢・地図同時推定法 (2008).
- [Folkesson 07] John Folkesson, Henrik I. Christensen.: SIFT Based Graphical SLAM on a Packbot, pp. 317–328 (2007)
- [Williams 09] Brian Williams, Mark Cummins, José Neira, Paul Newman, Ian Reid and Juan Tardós.: A comparison of loop closing techniques in monocular SLAM, Robotics and Autonomous Systems (2009)
- [Tenenbaum 00] Tenenbaum, J. B., Silva, V. D., & Langford, J. C.: A global geometric framework for nonlinear dimensionality reduction. *Science*, 290, (2000) 2319–2323.
- [Okatani 07] Okatani, T., Deguchi, K.: On the Wiberg Algorithm for Matrix Factorization in the Presence of Missing Components. *International Journal of Computer Vision* 72(3), (2007) 329–337