

# 観測履歴の次元削減による地図獲得法

## Map Building By Dimensionality Reduction of Observation History

矢入健久

Takehisa YAIRI

東京大学

University of Tokyo

In this study, we attempt to reformulate the problem of robotic map building from the viewpoint of dimensionality reduction, and propose a novel framework named *Localization-Free Mapping by Dimensionality Reduction* (LFMDR). In this framework, map building is interpreted as a problem of reconstructing a 2-D coordinates of objects so that they maximally preserve the local proximity of them in the space of robot's observation history. We apply this framework to two map building problems – (1) visibility-only mapping and (2) bearing-only mapping, and demonstrate that a variety of dimensionality reduction techniques can be used to obtain maps in both cases.

### 1. はじめに

近年の移動ロボット地図作成法に関する研究の多くは、SLAM(Simultaneous Localization and Mapping) [Thrun 02] の枠組、すなわち、観測と移動の履歴からロボットの移動軌跡と外部物体の位置を同時に推定する問題としての定式化を採用している。また、実際に SLAM 問題を効率的に解くアルゴリズムも開発されており、実用的にも成功を納めている。

無論、著者も SLAM 研究の意義や価値に対して何ら異義を唱えるつもりはない。しかし、「ロボット地図作成イコール SLAM」といわんばかりの風潮には違和感を感じるし、SLAM 以外の地図作成方法論に対しても注意が払われるべきだと考える。そこで、本稿ではまず、ロボット地図作成、特に SLAM 方法論に関して以下の問題を提起したい。

1. SLAM では地図作成と自己位置推定が表裏一体になっていること(いわゆる「にわとりと卵」の関係)を前提としているが、自己位置推定を行わずに観測データから直接的に外部物体の位置を推定しても良いのではないか？
2. SLAM では観測・移動モデルが事前に与えられることを前提とするが、これらを必要としない、あるいは、より「弱い」事前知識だけを使った地図作成法も有りうるのではないか？
3. 確かに SLAM は工学的には優れた地図作成方法論であるが、例えば人間の認知地図のような実世界の表象(あるいは低次元表現)としての「地図」の獲得プロセスに関してはほとんど何も説明しないのではないか？

本稿では、このような疑問を主な動機として、SLAM とは異なる新たな地図作成フレームワーク「次元削減に基づく自己位置推定不要な地図学習」(Localization-Free Mapping by Dimensionality Reduction: LFMDR) を提案する。これは、直感的には「空間的に近接している物体は、観測履歴が似ている」という経験則を利用した方法である。言い替えば、LFMDR は、高次元のロボットの観測履歴空間において計算される各物体間の(局所的な)近接性をできるだけ忠実に保存するように、実空間での座標を決定する。具体的な次元削減法として

連絡先: 矢入健久, 東京大学先端科学技術研究センター, yairi@space.rcast.u-tokyo.ac.jp

は、PCA などの線形手法だけではなく、近年発展著しい非線形次元削減法、いわゆる多様体学習法も利用できる。

LFMDR の最大の特徴は、地図作成が自己位置推定から完全に独立していること、および、事前知識をほとんど要求しないこと、の2点である。すなわち LFMDR は、自己位置推定を行わずに、また、観測・移動モデルを(陽に)用いずに、外部物体位置を推定する。もっとも、これらの LFMDR の長所にはそれ相応の犠牲も伴う。具体的には、推定アルゴリズムは基本的にバッチ処理であるし、事前知識をほとんど使わない分、観測データを SLAM よりも多く必要とする。

本稿ではまた、LFMDR を物体可視情報と相対方位計測にそれぞれ適用した2つの実装例とその実験結果も紹介する。

### 2. 次元削減による物体位置推定

#### 2.1 地図学習の従来枠組 (SLAM)

まず、ロボット地図作成法の現在の主流である SLAM 方法論 [Thrun 05] を振り返ってみる。ただし、SLAM は占有グッド地図やトポロジカル地図など様々な表現形式に対して適用可能な枠組であるが、本稿では専ら、有限個の物体(特徴)の座標集合によって表現される特徴ベース地図(feature-based map)を考えるものとする。

また、これ以降、変数と記号を以下のように定義する。

- $x_t$ : 時刻  $t$  におけるロボットの状態(位置と姿勢)
- $m = \{\xi_1, \xi_2, \dots, \xi_M\}$ : 地図(外部物体の位置座標)
- $u_t$ : 時刻  $t$  から  $t+1$  までのロボットの制御量
- $y_t$ : 時刻  $t$  におけるロボットの観測

SLAM では、これらの変数間に、以下の状態方程式と観測方程式によって表される関係が成り立つことを前提としている。

$$x_t = f(x_{t-1}, u_{t-1}, m) + v_t \quad (1)$$

$$y_t = g(x_t, m) + w_t \quad (2)$$

ただし、 $v_t, w_t$  は、それぞれ外乱と観測ノイズを表す。

このとき、SLAM 問題は、「観測履歴  $\{y_{1:N}\}$  と制御履歴  $\{u_{1:N-1}\}$  が与えられたときに、ロボットの状態履歴  $\{x_{1:N}\}$  と外部物体座標  $m$  を推定すること」として定義される。SLAM 問題の代表的な解法としては、ロボット状態と全物体位置を結合した拡張状態に対して拡張カルマンフィルタ(EKF)を適用する方法 [Leonard 99], EM アルゴリズムによって両者を交互に




図 1: 観測履歴の次元削減に基づく物体位置推定

推定する方法 [Thrun 98], 問題を分解して Rao-Blackwellized Particle Filter を適用する方法 [Montemerlo 02] などがある.

しかし, いずれの SLAM 手法においても, 式 1, 2 の状態方程式と観測方程式が事前に与えられることが前提となっており, また, たとえ地図だけを得たい場合でもロボットの各時刻における状態も同時に推定する必要がある. 一方, 後に述べるように, 提案する LFMDR はそれらの必要が無い.

## 2.2 次元削減と地図作成

次元削減とは, 高次元データの低次元表現を求めることを目的とする多変量解析の主要テーマの一つであるが, 画像・パターン認識, データマイニングなど高次元データを扱う様々な応用分野においても中心的な話題になってきた. 特に, 主成分分析 (PCA) は, 最も基本的かつ広く用いられている次元削減手法であるが, 近年では多様体学習 [Saul 06] と呼ばれる非線形な次元削減法も盛んに研究されている.

これらの次元削減法は, データ可視化, クラスタリング, 分類・回帰学習など様々な分野で利用されているが, 特に, 移動ロボット研究における興味深い応用例が, 観測データの次元削減による自己位置推定である [Ham 05, Bowling 05, Ferris 07]. これらの研究は, 移動ロボットの高次元観測ベクトル時系列を次元削減することによって低次元の状態遷移を復元する手法, すなわち, 「地図無しでロボットの自己位置を推定する」方法を提案しており, 本稿で提案する「自己位置推定無しで地図を作成する」方法と相補的な関係にある. これらの手法は, 単に自己位置を推定するだけでなく, 式 2 の観測モデルを学習していることに着目すれば, 広義の地図作成法と考えることもできる. また, 次元削減を地図作成に用いた他の例として, 確率的主成分分析 (PPCA) を用いてセンサーデータから環境の局所的な低次元形状要素を抽出する研究 [Brunskill 05] もあるが, 本稿で提案する LFMDR は環境中の大局的な地図の獲得を目的としている点で大きく異なる.

## 2.3 観測履歴の次元削減による物体位置推定

本節では, 移動ロボットによる地図学習を各外部物体についての観測履歴ベクトルの次元削減問題として定式化する. ただし, 問題設定に関して以下の仮定を置く.

まず, 外部物体のうち少なくとも 3 つ以上の物体については絶対位置が既知であるとする. これらをアンカー物体と呼ぶ. アンカー物体は作成された地図のスケール, 回転, 平行移動などの自由度を消すために用いられる.

次に, 観測の分離可能性, すなわち, ロボットの各時刻にお

ける観測  $y_t$  が, 次式のように, 各外部物体に関する成分ごとに分解可能であることを仮定する.

$$y_t = [y_t^{(1)}, y_t^{(2)}, \dots, y_t^{(M)}]^T \quad (3)$$

さらに, 以下のように観測モデル  $g$  が近似的に各物体ごとに分解されるという仮定を置く.

$$g(x_t, m) \approx [g_{m,x_t}(\xi_1), \dots, g_{m,x_t}(\xi_M)] \quad (4)$$

これは, 「ある物体配置  $m$  とロボット位置  $x_t$  が与えられたとき, 物体  $j$  に関する観測  $y_t^{(j)}$  がその物体位置  $\xi_j$  のみに依存する」ということを意味する. 言い替えば, ここで考える観測とは, 物体の特性 (種類や形など) ではなく, 物体とロボットとの空間の関係 (距離とか方向とか) に限定される.

以上の前提条件下において, 時刻  $t = 1, 2, \dots, N$  での観測履歴を考えると,  $y_{1:N}^{(j)} \in \mathcal{A}^N$  と  $\xi_j \in \mathcal{R}^2$  との間に非線形マッピング  $\Psi_{m,x_{1:N}}$  が存在すると考えることができる. ただし,  $\mathcal{A}$  は  $y_t^{(j)}$  が値を取る空間を表すとする.

$$\begin{aligned} y_{1:N}^{(j)} &= \begin{bmatrix} y_1^{(j)} \\ \vdots \\ y_N^{(j)} \end{bmatrix} = \begin{bmatrix} g_{m,x_1}(\xi_j) \\ \vdots \\ g_{m,x_N}(\xi_j) \end{bmatrix} \\ &\equiv \Psi_{m,x_{1:N}}(\xi_j) \end{aligned} \quad (5)$$

今, 関数  $g$  や  $\Psi_{m,x_{1:N}}$  は明示的には与えられず, データとして  $y_{1:N}^{(1)}, \dots, y_{1:N}^{(M)}$  のみが与えられたときに, それらの点に対応する低次元の  $\xi_1, \dots, \xi_M$  を求めることを考える. この場合, 地図獲得とは, 一連の  $N$  回の観測によって得られた  $M$  個の  $N$  次元ベクトルによって表される外部物体を, 低次元 (2 次元) での座標に変換すること, すなわち, 次元削減問題であると考えることができる. 図 1 は, 観測履歴の非線形次元削減に基づく物体位置推定の考え方を図示したものである.

要約すると, 提案アルゴリズム (LFMDR) の基本手続きは次のように記述される.

1. ロボットは環境内を移動しつつ観測を行うことによって, 時刻  $N$  までの観測履歴データ  $Y_{1:N}$  を得る.
2.  $Y_{1:N}$  を各物体に対応する列ベクトルに分解し,  $M$  個の観測履歴ベクトル  $\{y_{1:N}^{(1)}, \dots, y_{1:N}^{(M)}\}$  を得る.
3.  $M$  個のベクトル  $\{y_{1:N}^{(j)}\}_{j=1, \dots, M}$  あるいは適当に正規化した  $\{\tilde{y}_{1:N}^{(j)}\}_{j=1, \dots, M}$  に対して, 好きな次元削減法を適用し, 2 次元ベクトル  $\{z_j\}_{j=1, \dots, M}$  を得る.
4. アンカー物体に関する位置誤差を最小化するようなアフィン変換を求めて,  $\{z_j\}_{j=1, \dots, M}$  に適用し, 全物体の推定位置  $\{\hat{\xi}_j\}_{j=1, \dots, M}$  を得る.

この次元削減問題による地図作成の特徴は以下のように要約される. まず, 観測履歴から直接物体位置を求めるので, 自己位置推定を行う必要がない. また, 観測・移動モデルに関する事前知識の要求が極めて少ない. 具体的には, 観測  $y_t$  および観測モデル  $g(m, x_t)$  が上で述べた条件を満たささえすれば良く,  $g$  や  $f$  そのものが具体的に分かる必要はない.

一方, LFMDR の欠点の一つは, 基本的にはバッチ式のアルゴリズムであることである. つまり, 新たなデータが得られる度に再計算する必要がある. また, 観測・移動モデルという質の高い情報を利用しない代償として, SLAM に比べて多く




図 2: 可視情報のみによる地図作成 (VOM) において各次元削減法 (LPCA, SMACOF, KPCA, ISOMAP) を用いた場合の平均誤差変化




図 3: 可視情報のみによる地図作成 (VOM) において各次元削減法 (LPCA, LLE, LEM, HLLE, SDE) を用いた場合の平均誤差変化

の観測データを必要とする。加えて、LFMDR は観測データが完全であること、すなわち、欠損値が含まれないことを想定している。不完全データを扱わなければならない場合には、例えば EM アルゴリズムなどを利用して、欠損値を同時推定しながら次元削減を行う必要がある。

### 3. 物体可視情報と相対方位計測への適用

本章では LFMDR の枠組を物体可視情報 (visibility information) と物体方位計測 (bearing information) に対してそれぞれ適用した場合に導出される “Visibility-only localization-free mapping” (VOLFM) および “Bearing-only localization-free mapping” (BOLFM) を紹介する。

#### 3.1 共通設定

2.5m 四方の正方形型の領域の中に  $M = 50$  個の物体 (直径 48mm) がランダムに配置されているような環境を考える。また、そのうち 4 個がアンカー物体であるとする。ロボットは、ランダムな進行方向選択と衝突回避を行いながら、各地点で各物体の可視情報あるいは相対方位情報を記録する。

今回の実験では、各比較設定について、5 つの物体配置パターンに対してそれぞれ初期状態をランダムに設定して 5 回ずつ試行を行うことによって、計 25 回の試行を行った。

#### 3.2 利用した次元削減法

今回は以下の 8 種類の次元削減法を利用し結果を比較した。

1. 線形主成分分析 (LPCA)
2. 多次元尺度構成法 (SMACOF 法)[de Leeuw, 1977]
3. カーネル PCA (KPCA)[Scholkopf 98]
4. Isometric Feature Map (ISOMAP)[Tenenbaum 00]
5. Locally Linear Embedding (LLE)[Roweis 00]
6. Laplacian Eigenmap (LEM)[Belkin 02]
7. Hessian LLE (HLLE)[Donoho 03]
8. Semi-definite Embedding (SDE)[Weinberger 05]

ただし、SMACOF 法では物体間距離に重み付けを行う場合と行わない場合を、KPCA ではガウシアンカーネルと多項式カーネルをそれぞれ試した。また、ISOMAP, LLE, LEM, HLLE, SDE, および、重み付けあり SMACOF は、いずれも  $k$ -近傍法によって近傍グラフを構成した。

#### 3.3 ケース 1: 物体可視情報のみによる地図作成 (VOLFM)

「可視情報のみによる地図作成」(Visibility-Only Mapping: VOM) では、全方位カメラを持つロボットが各観測地点において各物体が「見えるか見えないか」という情報だけを使って全物体位置を推定する。今回のシミュレーション設定では、物体の平行視角が 5 degree 以上の大きさのときに「見える」とした。この条件は、物体がロボットから約 550mm 以内にありかつ他の物体に遮蔽されていないという状況に対応する。

VOM では、 $N$  時刻後の観測履歴データ  $Y_{1:N}$  は、 $N$  行  $M (= 50)$  列の 0-1 行列によって表される。従って、LFMDR をこの観測データに適用すると、 $M$  個の  $N$  次元のバイナリベクトル  $\{y_{1:N}^{(1)}, \dots, y_{1:N}^{(M)}\}$  の 2 次元平面への埋め込みの問題になる。ただし、現実には、物体の「見えやすさ」は配置などによって異なるため、前処理として各可視観測履歴ベクトルが大きさ 1 になるように規格化を行う。

図 2,3 は、各次元削減法を用いた場合において、作成地図の平均位置誤差 (MPE) が利用データ数にともなってどのように変化していくかを示したものである。まず、一般的に言えることとして、観測データが増えるにつれて作成地図の精度が向上することがわかる。次に、各次元削減手法間で結果を比較してみると、カーネル PCA を除く非線形次元削減手法はいずれも、線形の次元削減法である線形 PCA を凌駕している。これは「近い物体しか見えない」という VOM の問題設定では局所的な近傍性を重視するこれらの非線形手法が有利であることを示しており、妥当と言える。

興味深い点のひとつは、古典的な手法である SMACOF 法が ISOMAP などの最新多様体学習法に匹敵する成績を挙げていることである。ただし、SMACOF 法は局所解を防ぐために適切な初期解を与える必要がある。今回は、線形 PCA によって得られた解を初期解として利用することによって良好な結果が得られた。

#### 3.4 ケース 2: 相対方位計測のみによる地図作成 (BOLFM)

「相対方位計測のみによる地図作成」(Bearing-Only Mapping: BOM) では、機軸に対する各物体への相対方位角 (Bearing) 情報だけを用いて全物体の位置を推定する。

相対方位角計測に対して LFMDR の枠組を適用する場合の問題点は、角度の  $-pi$  と  $pi$  の境界における不連続性である。そのため、本研究では時刻  $t$  における物体  $j$  への相対方

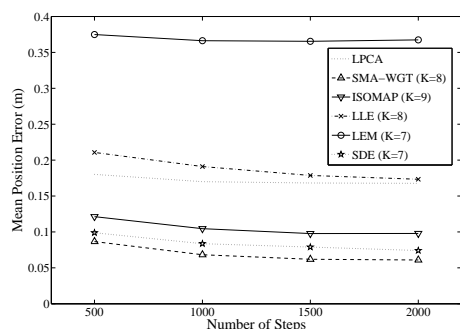


図 4: 相対方位計測のみによる地図作成 (BOM) において各次元削減法 (LPCA, SMACOF, ISOMAP, LLE, LEM, SDE) を用いた場合の平均誤差変化

位角度  $\theta_{t,j}$  をそのまま用いるのではなく、単位方向ベクトル  $[\cos \theta_{t,j}, \sin \theta_{t,j}]^T$  を用いる。

図 4 は各次元削減手法を用いた場合に MPE がどのように変化するかを示している。ただし、HLLE は計算が不安定であったため除外した。また、KPCA は他の手法と比較して結果が著しく劣ったためこの図には示していない。

まず全体として、前節の VOM と比べて高い精度で地図が作成されている。これは、一般に相対方位計測の方が可視情報よりも高質な空間情報を含んでいることを考えれば妥当な結果である。次に、VOM での結果との大きな違いは、線形次元削減法である LPCA が非常に良い性能を示している点である。その一方で、意外にも LLE や LEM などの局所近傍性や局所線形性を仮定している非線形次元削減法は LPCA にも劣る結果に終わった。この現象の主な理由は、全ての物体が「見える」という仮定によって観測空間の局所性の効果が小さくなったためと考えられる。言い替えば、この場合の観測履歴空間は 2 次元実空間における物体間の距離尺度を大域的に良く保存しているためにこのような結果になったと考えられる。

#### 4. おわりに

本稿は移動ロボットによる地図作成を次元削減問題という観点から再考し、LFMDR という新たな方法論を提案した。SLAM とは異なり、この地図作成法は自己位置推定を必要としないことに加えて観測モデルを事前に知る必要も無い。また、本稿では、LFMDR を物体可視情報と相対方位計測に対してそれぞれ適用することによって導出される“Visibility-only localization-free mapping” (VOLFM) と“Bearing-only localization-free mapping” (BOLFM) も紹介し、実験において様々な次元削減法を利用して結果を比較した。LFMDR は相対距離計測 (range) など他の様々な空間的計測にも適用することができる。

一方で、実環境での適用に関しては様々な課題がある。例えば、欠損値が存在する場合の対処や、アルゴリズムのオンライン化などである。今後の研究ではこれらの問題に対して有効な解決策が示されることが期待される。

#### 参考文献

[Thrun 02] Thrun, S. . Robotic mapping: A survey. In *Exploring artificial intelligence in the new millenium*. Morgan Kaufmann (2002).

[Montemerlo 02] Montemerlo, M., et.al, Fastslam: A factored solution to the simultaneous localization and mapping problem. *Proc. AAAI* pp.593–598 (2002).

[Thrun 05] Thrun, S., et.al, *Probabilistic robotics*. MIT Press. (2005).

[Leonard 99] Leonard, J., & Feder, H. A computationally efficient method for large-scale concurrent mapping and localization. *Proc. Int. Symp. on Robotics Research*. (1999).

[Thrun 98] Thrun, S., et.al, A probabilistic approach to concurrent mapping and localization for mobile robots. *Machine Learning*, 31, 29–53. (1998).

[Scholkopf 98] Scholkopf, B., et.al, Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 10, 1299–1319. (1998).

[Saul 06] Saul, L. K., et.al, *Semisupervised learning*, chap. 16: Spectral methods for dimensionality reduction, 279–294. MIT Press. (2006).

[Ham 05] Ham, J., et.al, Learning nonlinear appearance manifolds for robot localization. *Proc. IROS* (pp. 1239–1244). (2005).

[Bowling 05] Bowling, M., et.al., Action respecting embedding. *Proc. ICML* (pp. 65–72). (2005).

[Ferris 07] Ferris, B., et.al., WiFi-SLAM Using Gaussian Process Latent Variable Models. *Proc. IJCAI* (pp. 2480–2485). (2007).

[Brunskill 05] Brunskill, E. and Roy, N. SLAM using Incremental Probabilistic PCA and Dimensionality Reduction. *Proc. ICRA*. (2005).

[de Leeuw, 1977] de Leeuw, J. Applications of convex analysis to multidimensional scaling. In *Recent developments in statistics*, (pp. 133–145). North-Holland. (1977).

[Tenenbaum 00] Tenenbaum, J. B., et.al., A global geometric framework for nonlinear dimensionality reduction. *Science*, 290, (pp. 2319–2323). (2000).

[Roweis 00] Roweis, S., & Saul, L. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 290, (pp. 2323–2326). (2000).

[Belkin 02] Belkin, M., & Niyogi, P. Laplacian eigenmaps and spectral techniques for embedding and clustering. *Proc. NIPS* (pp. 585–591). (2002).

[Donoho 03] Donoho, D. L., & Grimes, C. *Hessian eigenmaps: new locally linear embedding techniques for high dimensional data* (Technical Report). Dept. of Statistics, Stanford University. (2003).

[Weinberger 05] Weinberger, K., et.al., Nonlinear dimensionality reduction by semidefinite programming and kernel matrix factorization. *Proc. AISTATS*. (2005).