

## 論文

## 準動的環境における移動ロボットの地図生成と位置決め

周 洪鈞<sup>\*1)</sup> 坂根 茂幸<sup>\*2)</sup>

## Mapping and localization for mobile robot in semi-dynamic environment

Hongjun Zhou<sup>\*1)</sup>, Shigeyuki Sakane<sup>\*2)</sup>

Mapping and localization play important roles for autonomous mobile robots. Since most of the conventional mapping methods assume a static environment, the obtained map lacks reliability for localization when a real environment violates the assumption. In this paper, we deal with mapping in environments containing semi-dynamic objects such as cabinets with wheels, chairs, and doors which can be moved occasionally. We propose SLAM-SD, an extended SLAM method for semi-dynamic environments, which allows simultaneous localization of a robot, mapping of the environment, and localization of semi-dynamic objects. The method can update an occupancy grid map properly when semi-dynamic objects have been moved. We conducted experiments using a mobile robot equipped with a LRF and an IC tag reader. The results show the effectiveness of the SLAM-SD.

キーワード：移動ロボット、環境地図生成、位置決め、準動的環境、IC タグ

Keywords : mobile robot, mapping, localization, semi-dynamic environment, IC tag

## 1. 初めに

近年、ロボットの環境地図生成と自己位置決めとを同時に行う SLAM (Simultaneous Localization and Mapping) の技術が発展している<sup>(1)(2)(3)(4)</sup>。しかし、従来の SLAM の殆どは静的環境を仮定している。そのため、もしも環境に動的物体が存在して、そのポーズ(位置・姿勢)が変化すると、センサ情報と環境地図との誤対応により、ロボットの自己位置決め信頼性が著しく低下する問題がある。

本研究では、屋内環境にある物体を、物体のポーズの変化の頻度に基づいて、静的物体、動的物体、準動的物体に分ける。すなわち、壁や大きな家具など動かないとしてもよいものは静的物体であり、歩行する人間のように頻繁に動く物体は動的物体である。そして、普段には移動される場合が少なく、常に移動している物体より動く頻度が低く、時々動く可能性のあるものを準動的物体と呼ぶ。例えば、オフィス環境では、可動型キャビネット、ドア、椅子などで、そのポーズが時々変化するがその頻度は動的物体よりも少ない。地図作成時には静止していると見なしてもよい物体である。

動的物体を扱う従来研究には文献<sup>(1)(2)</sup>等がある。地図作成時にロボットは動的物体を追跡し、その影響を環境地図から削除する。ロボットは走行する時に動的物体の動きを検出し位置推定の誤りを減らす。ただし、準動的物体の場合にはロボットが作業する時には動かず、作業しない時にその位置が動かされる場合が多い。そのために、ロボットは

準動的物体の動きを内外センサで検出することが難しい。

準動的環境の地図生成と位置決めの問題を対応するために、本論文では、環境地図の生成、ロボットの自己位置決め、および、準動的物体のポーズの推定を同時に行う手法 SLAM-SD (Simultaneous Localization and Mapping for Semi-Dynamic Environment) を提案する。本手法では、移動ロボットのポーズ、環境地図、準動的物体のポーズ、LRF (Laser Range-finder) のスキャンデータ情報、および、IC タグの検出情報、の依存関係を動的ベイジアンネットワーク (Dynamic Bayesian Network, 以下では DBN と略す) で表現し、変数の高次元化を緩和する RBPF (Rao-Blackwellised Particle Filter)<sup>(5)(6)</sup> を用いて、最適な環境地図、ロボットのポーズ、および、準動的物体のポーズを同時に推定する。静的物体、および、準動的物体を含む地図の表現には、占有グリッド (Occupancy grid)<sup>(7)</sup> を用いている。準動的物体のポーズが変化した場合には、そのポーズを表す占有グリッドの値を更新し、その時点までに生成してきた地図の更新を行う。そして、LRF と IC タグリーダを搭載する移動ロボットを用いた実験により、提案手法の有効性を確認した。




図1 SLAM-SD を推定するための DBN

\*1) IT グループ

\*2) 中央大学理工学部経営システム工学科

## 2. RBPf を用いた SLAM-SD

本手法 SLAM-SD では、RBPf を用いて、環境地図の生成、ロボットの自己位置決め、および、準動的物体のポーズの推定を同時に行う。図1の様に環境地図(M)、ロボットのポーズ(X)、準動的物体のポーズ(D)、センサ情報(Z)、の依存関係を DBN 表現する。ノード  $X_t$  とノード  $D_t$  は、それぞれ時刻  $t$  にロボットのポーズとロボットに検出された準動的物体のポーズを表す。ノード  $Z_t$  は時刻  $t$  にロボットのセンサ情報をしており、LRF のスキャンで得る距離データと、IC タグリーダ (およびアンテナ) による IC タグの検出の有無の情報を含んでいる。時刻  $t$  におけるロボットのオドメトリ情報を  $U_t$  で、環境地図をノード  $M_t$  で表す。  $I_t$  は時刻  $t$  に準動的物体のポーズを表す。また、図.1 の矢印は各ノード間の依存関係を表している。

### 2.1 ロボットと準動的物体のポーズの推定

下記の式(1)は、DBN のモデルでセンサ情報のノード値  $Z_{1:t}$  とオドメトリ情報のノード値  $U_{0:t}$  が与えられたときの、3つの隠れ状態に関するノード値 (すなわち、ロボットのポーズ  $X_{1:t}$ 、準動的物体のポーズ  $D_{1:t}$ 、及び環境地図  $M_t$ ) の条件付き確率を表したものである。式(1)を展開すると式(2)になる。

$$P(X_{1:t}, D_{1:t}, M_t | Z_{1:t}, U_{0:t}) \quad (1)$$

$$= P(M_t | X_{1:t}, Z_{1:t}) \times P(X_{1:t}, D_{1:t} | Z_{1:t}, U_{0:t}) \quad (2)$$

式(2)の  $P(M_t | X_{1:t}, Z_{1:t})$  は、ロボットのポーズ情報  $X$  とセンサデータ  $Z$  が与えられたときに、環境地図  $M$  を推定する事後確率 [7] であり、これは解析的に求めることが可能である。そして、式  $P(X_{1:t}, D_{1:t} | Z_{1:t}, U_{0:t})$  は、センサデータとオドメトリ情報が与えられたときの、ロボットと準動的物体のポーズの事後確率である。RBPf では、この事後確率分布をパーティクルフィルタで近似する。ロボットと準動的物体のポーズの推定は、以下に示す「予測」と「更新」の2ステップから構成されている。「予測」は、時刻1から  $t-1$  までのセンサ情報とオドメトリ情報に基づいた、時刻  $t$  におけるロボットと準動的物体のポーズの結合確率である。

予測:

$$\begin{aligned} & P(X_{1:t}, D_{1:t} | Z_{1:t-1}, U_{0:t-1}) \\ &= \sum_{X_{t-1}} \sum_{D_{t-1}} P(X_t | X_{t-1}) \times P(D_t | D_{t-1}) \\ & \quad \times P(X_{t-1}, D_{t-1} | Z_{1:t-1}, U_{0:t-1}) \end{aligned} \quad (3)$$

ここで、 $P(X_{1:t-1}, D_{1:t-1} | Z_{1:t-1}, U_{0:t-1}) = B_{t-1}$  と置き換えると、式(3)は次の様に書き直せる。

$$= \sum_{X_{t-1}} \sum_{D_{t-1}} P(X_t | X_{t-1}) \times P(D_t | D_{t-1}) \times B_{t-1} \quad (4)$$

ステップ「更新」では、ベイズの定理を用いて、予測した式(3)にセンサ情報とオドメトリ情報の事前確率を掛け合わせて  $B_t$  を求める。

更新:

$$\begin{aligned} B_t &= P(X_{1:t}, D_{1:t} | Z_{1:t}, U_{0:t}) \\ &= \eta \times P(Z_t, U_t | X_t, D_t) \times P(X_t, D_t | Z_{1:t-1}, U_{0:t-1}) \\ &= \eta \times P(Z_t, U_t | X_t, D_t) \times \\ & \quad \sum_{X_{t-1}} \sum_{D_{t-1}} P(X_t | X_{t-1}) \times P(D_t | D_{t-1}) \times B_{t-1} \end{aligned} \quad (5)$$

$\eta$  は確率を正規化するための定数である。式

$P(Z_t, U_{0:t} | X_t, D_t)$  はセンサデータの事前確率である。この事前確率を展開すると次の式となる。

$$\begin{aligned} P(Z_t, U_t | X_t, D_t) &= P(Z_t | D_t) \times P(Z_t | X_t) \\ &= P(I_t | D_t) \times P(L_t | D_t) \times P(L_t | X_t) \end{aligned} \quad (6)$$

確率  $P(I_t | D_t)$  と  $P(L_t | D_t)$  は、それぞれ準動的物体のポーズに基づいた IC タグの有無と LRF のスキャンデータの事前確率である。 $P(L_t | X_t)$  はロボットのポーズに基づいた LRF スキャンデータの事前確率である。センサデータの事前確率  $P(Z_t, U_t | X_t, D_t)$  を「センサモデル」と呼ぶ。

### 2.2 RBPf を用いた SLAM-SD の推定

準動的物体に対する IC タグの相対座標と準動的物体の幾何形状のモデルは共に IC タグに記述された物体の ID データ (ポイント) 経由で取り出すことが可能という前提から、IC タグのポーズを検出することにより準動的物体のポーズが推定できる。IC タグのポーズは3つの自由度  $x, y, \theta$  を含んだベクトルである。その3自由度は、各 IC タグの  $x, y$  グローバル座標と、IC タグ正面からみた法線ベクトルの  $x, y$  平面の方向である。ロボットのポーズも3自由度  $x, y, \theta$  を含んだベクトルである。 $x, y$  はロボットのグローバルな2次元位置座標、はロボットの(2次元)姿勢である。ロボットと準動的物体のポーズは式(5)により推定する。本手法では、sequential importance sampling という近似的な手法で式(5)を推定する。ロボットは時刻  $t-1$  から時刻  $t$  にロボットと準動的物体のポーズの状態遷移する確率  $P(D_t | D_{t-1})$

と  $P(X_t | X_{t-1})$  を以下の分布で推定する。

$$q(X_{1:t}, D_{1:t} | Z_{1:t-1}) =$$

$$P(D_t | D_{t-1}) \times P(X_t | X_{t-1}) \times P(D_{1:t-1}, X_{1:t-1} | Z_{1:t-1})$$

$q(X_{1:t}, D_{1:t} | Z_{1:t-1})$  は前時刻の観測データに基づいた現時刻におけるロボットと準動的物体のポーズの提案分布である。この提案分布は，次の重みに基づいて  $B_t$  を更新する。

$$\omega_t = \frac{P(X_{1:t}, D_{1:t} | Z_{1:t})}{q(X_{1:t}, D_{1:t} | Z_{1:t-1})} \propto P(Z_t, U_t | X_t, D_t)$$

環境地図生成，ロボットのポーズの推定，および，準動的物体のポーズの計算は，以下の4ステップの繰り返しにより行われる：

**SLAM-SD アルゴリズム：**

**1. 初期化： ( $t=1$ )**

- ・ ロボットのポーズとロボットに搭載したRFIDアンテナの検出範囲によりN個のパーティクル ( $i=1, \dots, N$ ) を一様分布で生成し，時刻tは2に設定する。

**2. パーティクルの予測：**

- ・ N個のパーティクル ( $i=1, \dots, N$ ) は遷移確率により時刻  $t-1$  状態から時刻tの状態に遷移する。状態遷移確率は以下のようになる。

$$\tilde{D}_t^{(i)} \leftarrow P(\tilde{D}_t^{(i)} | D_{t-1}^{(i)})$$

$$\tilde{X}_t^{(i)} \leftarrow P(\tilde{X}_t^{(i)} | X_{t-1}^{(i)})$$

- ・ ここで， $\tilde{D}_t^{(i)}$ ,  $\tilde{X}_t^{(i)}$  は状態遷移確率 ( $P(\tilde{D}_t^{(i)} | D_{t-1}^{(i)})$  と  $P(\tilde{X}_t^{(i)} | X_{t-1}^{(i)})$ ) に基づき予測されたパーティクルの状態である。
- ・ 重みにより各パーティクルの尤度を評価する。

$$\begin{aligned} \omega_t^{(i)} &\propto P(Z_t, U_t | D_t^{(i)}, X_t^{(i)}) \\ &= P(I_t | D_t^{(i)}) \times P(L_t | D_t^{(i)}) \times P(L_t | X_t^{(i)}) \end{aligned}$$

- ・ 上の式は，RFID アンテナ，レーザセンサなどにより計算したパーティクルを更新するための尤度である。
- ・ 計算した尤度は正規化する。

**3. パーティクルの更新：**

- ・ 前ステップで計算した尤度に基づき Residual Resampling アルゴリズム [8] によりパーティクルを再サンプリングする。
- ・ パーティクルの効率を評価するパラメータ  $N_{eff}^{(9)}$  を計算する。

$$N_{eff} = \frac{1}{\sum_{i=1}^N (\omega^{(i)})^2}$$

- ・  $N_{eff}$  の最大なパーティクル集合の中で最大の重みを持つパーティクルのポーズは，ロボットとICタグのポーズである。

**4. 環境地図生成：**

- ・ 確率  $P(M_t^{(1)} | X_t^{(i)}, Z_{1:t})$  により各パーティクルに対応する環境地図  $M_t^{(1)}$  を生成する。
- ・ 時刻tは  $t+1$  に設定しステップ2に戻る。

**3. 実験**

本手法の有効性を評価するために，実ロボットから得たログデータを利用して SLAM-SD を実行した。実験に用いた移動ロボット (ActivMedia 製, Pioneer3) は UHF 帯 IC タグリーダー・ライター，RFID アンテナ (富士通製)，LRF (SICK 社製, LMS200) を搭載している。このアンテナが IC タグを検出できる最大距離は 2[m] である。また，IC タグのメモリ容量は 256byte (内ユーザ領域 192byte) である。実験に用いたコンピュータの CPU は AMD Athlon XP 3200+ であり，メモリは 1GB である。実験環境はドアとゴミ箱などの準動的物体を含む廊下環境である。




図2 ゴミ箱とドアなどを含む短い廊下で行った SLAM-SD 実験の結果

ドアの開閉は，屋内環境におけるロボットの走行に非常に大きな影響を与える。そこで，廊下環境において，準動的物体であるゴミ箱とドアのポーズ変化を検出し，それに伴い地図を更新する実験を行った。まず，ロボットは 10[m] × 3[m] の短い廊下環境で 2 つのドアと 2 つのゴミ箱を検出する実験を行った (図2)。SLAM-SD アルゴリズムに従って，ロボットは IC タグの ID 情報を検出した時，1000 個のパーティクルを一様分布で生成する。そして，SLAM-SD の STEP 2 から STEP 3 までの繰り返し処理によりパーティクルを収束されていく。最後，収束したパーティクルの平均位置と姿勢は検出した IC タグのポーズになる。図2の矢印のポーズは収束したパーティクルの平均位置と姿勢である。

図2の中に矢印は検出した IC タグの位置とタグが貼られた面の法線ベクトルの方向を示している。IC タグは物体に添付したので，ドアとゴミ箱の位置と姿勢は IC タグの位置



図3 長い廊下でゴミ箱とドアなどの検出実験の結果

と方法から推定できる。矢印と垂直になった棒のポーズは推定したドアの位置であり、矢印の始点にある箱の位置はゴミ箱の位置を示す。図2(a,b,c)は実際の準動的物体の写真である。写真に示された準動的物体のマッピング結果は、矢印が指している丸で囲まれた部分である。実験結果より、本手法が、ゴミ箱だけではなく、ドアの開閉の状態の検出についても正しく行えることを確認した。

アルゴリズムの一般性を検証するために、更に 50[m] × 3[m]の長い廊下環境で SLAM-SD 実験を行った。実験環境とロボットを図3(A)に、また、SLAM-SDの実験結果を図3(D)に示す。環境内には、大きいサイズのドア、小さいサイズのドア、および、ゴミ箱、の3種類の準動的物体が混在する。大きいサイズのドアの数が6個、小さいサイズのドアの数が7個、ゴミ箱が11個である。実験結果を見やすくするために、小さい丸で囲まれた環境地図の部分拡大し、環境地図の上側で対応した準動的物体の写真と並べて示した。図3(B)は廊下の真中の部分の実験結果の拡大した画像である。画像の隣は、この画像の下に示された検出したドアとドアのそばにあるゴミ箱の写真である。画像に示すように、ロボットが検出したドアの位置は実際のドアの位置から外れて、ゴミ箱の外側に重なるエラーを生じた。ロボットは、そのドアに添付したICタグを検出したときに、搭載したRFIDアンテナの検出範囲内にはドアとゴミ箱が両方あり、また、LRFでスキャンした距離データのパターンとレイトラッキングで生成したパターンとの差でドアとゴミ箱の外側を区別できないため、ドアの検出エラーを生じた。本実験の検出結果を表1にまとめた。小さいサイズのドアで2回エラーを生じた以外は、準動的物体であるドアの開閉の変化の検出ができており、複数種類の準動的物体が混在しても本手法が適用できることが検証された。廊下環境に於ける SLAM-SD 実験により生成した占有グリッドマップのグリッドのサイズは2[cm]である。SLAM-SDを実施するとき、パーティクルが毎回再サンプリングと更新などを行う計算時間は平均0.8秒である。

#### 4. 結論

移動ロボットの環境地図の生成において、従来の方法の多くは静的環境を前提としており、動的環境での地図生成の手法の開拓が課題であった。本論文では、移動ロボットの環境として、準動的物体を含む環境下でロボットの自己位置決めと地図生成を行うシステムの構成を目指し、環境

の SLAM-SD を行いながら準動的物体を検出・位置決めをする手法: SLAM-SD (Simultaneous Localization and Mapping for Semi-Dynamic Environment)を提案した。本手法では、ロボットのポーズ推定、準動的物体のポーズ推定、および、環境地図の生成を同時に行う。この結果に基づいて環境地図を更新する。LRF(レーザ距離センサ)とICタグを搭載する移動ロボットを用いて、可動キャビネット、ゴミ箱、ドアなどを含む準動的環境下で地図を生成する実験を行い、本提案手法の有効性を確認した。

表1. ゴミ箱とドアを含む長い廊下で SLAM-SD 実験の結果

	大きいサイズのドア	小さいサイズのドア	ゴミ箱
物体の数	6	7	11
正確に検出した数	6	5	11

(平成19年6月29日受付,平成19年7月13日再受付)  
文献

- (1) Denis Wolf, et al.: "Online simultaneous localization and mapping in dynamic environments", In Proc. of the Int. Conf. on Robotics and Automation (ICRA), 2004.
- (2) C. Wang, C. Thorpe, and S. Thrun: "Online simultaneous localization and mapping with detection and tracking of moving objects: Theory and Results from a Ground Vehicle in Crowded Urban Areas", Proc. of the IEEE Int. Conf. on Robotics and Automation (ICRA), 2003.
- (3) J. Leonard and H. Feder: "A Computationally efficient method for large-scale concurrent mapping and localization", In Robotics Research: The Ninth Int. Symp. Snowbird, UT: Springer Verlag, 2000.
- (4) D. Hahnel, W. Burgard, D. Fox, and S. Thrun: "A highly efficient FastSLAM algorithm for generating cyclic maps of large-scale environments from raw laser range measurements", In Proc. of the IEEE/RJSJ Int. Conf. on Intelligent Robots and Systems (IROS), 2003.
- (5) K. Murphy, "Bayesian map learning in dynamic environment", Neural Info. Proc. Systems (NIPS), 1999.
- (6) A. Doucet, N. de Freitas, K. Murphy and S. Russell: "Rao-Blackwellised particle filtering for dynamic Bayesian networks", Proc. of Conf. on Uncertainty in Artificial Intelligence (UAI), 2000.
- (7) H.P. Moravec, "Sensor fusion in certainty grids for mobile robots", AI Magazine, pages 61-74, Summer, 1988.
- (8) J. Liu and R. Chen: "Sequential Monte Carlo methods for dynamical Systems," Journal of the American Statistical Association, Vol. 93, pp. 1032-1044, 1998.
- (9) J.S. Liu: "Metropolized independent sampling with comparisons to rejection sampling and importance sampling", Statst. Comput. 6: pp. 113-119, 1996.
- (10) 周 洪鈞, 坂根 茂幸: 「ベイジアンネットワークの構造学習と推論を用いた移動ロボット位置決めのためのセンサプランニング」, 日本ロボット学会誌, Vol.22, No.3, pp.245-255, 2004.