

# 幾何地図上での観測物体の有無を考慮した自己位置推定<sup>†</sup>

赤井直紀\*・モラレスルイス 洋一\*\*  
平山高嗣\*\*・村瀬 洋\*

Localization Considering Known and Unknown Classes of Observed Objects on a Geometric Map

Naoki AKAI\*, Luis Yoichi MORALES\*\*,  
Takatsugu HIRAYAMA\*\* and Hiroshi MURASE\*

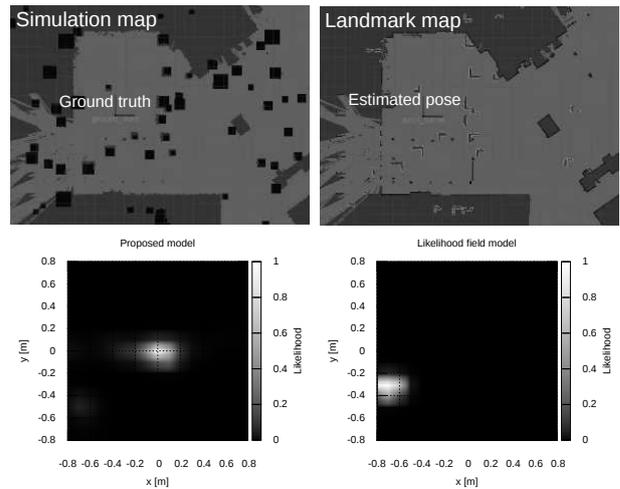
This paper presents a localization approach that simultaneously estimates a robot's pose and class of sensor observations, where "class" categorizes the sensor observations as those obtained from known and unknown objects on a given geometric map. The proposed approach is implemented using Rao-Blackwellized particle filtering algorithm. The robot's pose can be robustly estimated utilizing sensor observations obtained from the only known objects by the simultaneous estimation. The proposed approach is efficient in terms of computational complexity because its complexity is same as that of the likelihood field model. Performance of the proposed approach was shown through experiments using a 2D LiDAR simulator.

**Key Words:** Localization, Environment Recognition, Rao-Blackwellized Particle Filter

## 1. はじめに

一般的に自己位置推定(以下, 位置推定)を行う際には, センサ観測と幾何地図(以下, 地図)の間で対応関係を探査し, その対応を基に誤差関数を作成する. そして, その誤差が最小となる状態を最適化により求めることで, 位置推定結果とする [1]. もしくは, 移動やセンサ観測の不確かさを確率的にモデル化し, 最大事後確率となる状態を求めることで, 位置推定結果とする [2]. この際, 対応関係の探索処理や, センサ観測のモデル化(観測モデル)は, 環境変化の影響を容易に受け, 狙い通りのものとなることがある. しかし, 環境の動的変化を予測しながらこれらの処理を実現することは容易ではない. そこで本論文では, センサにより観測された物体の地図上での有無を考慮することで, 環境変化に対して頑健に位置推定を行うことが可能となる方法を提案する. なお本論文では, 確率的アプローチに着目する.

本提案のアイデアは「地図上に存在する既知物体からの得られるセンサ観測のみを用いて位置推定を行うこと」である. この実現のために, ロボット位置とセンサ観測のクラス, すなわち地図上での観測物体の有無, を同時に推定する方法を提案する. なお提案法は, ランドマークや占有格子表現を



**Fig. 1** Localization performance of the proposed approach in dynamic environments. Bottom figures show likelihood distributions around the ground truth  $((x, y) = (0, 0))$  by the proposed and likelihood field models.

用いたどちらの幾何地図にも対応した実装を行うことが可能であるが, 本論文では占有格子地図を用いた実装に焦点を当てる. そのため本論文では, ランドマークを「地図上に存在する非明示的な大きさや形状を有する障害物」と定義する. すなわち, 占有格子地図によりランドマークの大きさや形状を非明示的に表現するため, 障害物を有する格子もランドマークと呼ぶ. そして「ランドマークの観測」とは, センサのスキャン点, この格子に当たる状態を意味するものとする.

図 1 には, 提案法による位置推定結果の一例を示す. 図 1

<sup>†</sup> 第 24 回ロボティクスシンポジウムで発表 (2019・3)

\* 名古屋大学情報学研究所

\*\* 名古屋大学未来社会創造機構

\* Graduate School of Informatics, Nagoya University

\*\* Institute of Innovation for Future Society (MIRAI), Nagoya University

左上は、2次元 LiDAR の観測をシミュレートするための地図であり、黒色の四角形は動的（未知）障害物を表す。なお、シミュレーション用の地図からは、ランダムにランドマークを除去する処理も行われている。図1右上は、提案法によりロボット位置、およびセンサ観測のクラスを同時推定した結果である。未知障害物から得られている観測値が地図上に存在しない障害物であると判断されている（白色で覆われたスキャン点）。図1下は、提案法、および likelihood field model (LFM) [2] を用いて計算した真値  $((x, y) = (0, 0))$  周辺の尤度分布である。なおこの分布は、表示範囲の最大値を基準に正規化されている。図1左下が提案法により計算された尤度分布であり、未知障害物の存在やランドマークの移動・除去といった環境変化に影響を受けずに、真値周辺の尤度分布が高くなり、環境変化に対して頑健に尤度計算が実現できていることが確認できる。加えて提案法は、LFM と等しい計算量・メモリ使用量で実行でき、効率性の面でも優れる。

本論文の貢献は以下の通りである。

- 観測物体の地図上での有無を考慮（同時推定）しながら位置推定が行える方法（グラフィカルモデル）を提案すること。
- 提案グラフィカルモデルから条件付き観測モデルが導出されることを示すこと。
- 条件付き観測モデルを用いることで計算量の増大を避けながら位置推定のロバスト性を向上させられること。

本論文の構成は以下の通りである。2章では、関連研究をまとめる。3章では、提案法のグラフィカルモデル、およびその定式化に関して述べる。4章では、提案法の実装方法に関して述べる。5章では、提案法の評価・検証を行う。6章にて、本研究をまとめる。

## 2. 関連研究

環境の動的変化の主な要因は、歩行者や自動車などの動的障害物である。単純に自己位置推定のロバスト性を向上させる方法は、動的特性が高い物体を外れ値として扱い、位置推定の演算のために用いないことである [3] [4]。しかしこれらの方法では、駐車車両やランドマークの移動のような準動的な障害物に対処できない。近年では、マルチレイヤー LiDAR の様な大量の情報を一度に取得することが可能となり、多数決的に環境変化の影響を無視可能になっているともいえる [5] [6]。しかしこれらの方法は、根本的に環境変化に対処したのではなく、ロバストな位置推定を実現するためには、何かしらの未知障害物に対する対処法が必須である。

文献 [2] では、beam model (BM) が提案されている。BM は、ランドマーク前方の自由空間において、未知障害物を観測する可能性があることを仮定したモデルである。しかし BM は、計算コストや尤度分布が滑らかにならないといった問題を有する。文献 [2] では、これらの問題に対処するために LFM も提案されている。しかし LFM は、計算の高速性などのシステムとしての利点を優先したモデルであり、未知障害物を観測する可能性を考慮していないモデルとなっている。文献 [2]

では、BM を利用して未知障害物を観測している可能性の高いデータを、尤度計算前に棄却する方法も提案されている（詳細は 5.2 節で後述）。しかし前述の通り、BM はランドマークの除去・移動といった状態に対応できず、かつ BM による計算を行うため、計算コストが高くなる。

観測モデルの改良により動的変化に対処する方法も提案されている。Olufs らや Takeuchi らは、センサ観測の自由空間を活用した観測モデルを提案している [7] [8]。これらは、ランドマークの後方領域の観測に対して尤度を低下させるモデルである。しかし、左右どちらかにランドマークの存在しない領域が存在する地点において、位置推定が困難になるという問題がある。近年では、オンラインで観測誤差をモデル化するような観測モデルなども提案されている [9] [10]。しかしこれらは、あくまで観測残差のモデル化を行っているのみであり、未知障害物の認識などは行っていない。

環境が静的であるという仮定を捨て、環境変化をモデル化しようと試みた手法も提案されている [11] [12] [13]。これらの手法では、隠れマルコフモデルやマルコフ連鎖が利用され、環境変化に対して適応的に地図を更新することができる。また Wang らは、位置推定、地図構築・更新、および動的物体の追跡を同時に実行する方法を提案している [14]。Tipaldi らは、隠れマルコフモデルを適用し、適応的に地図を更新しながら位置推定を行う方法を提案している [15]。しかしながらこれらの手法は、位置と地図を同時推定するために、 Rao-Blackwellized particle filter (RBPF) の様な実装が必要となる。すなわち、各パーティクルが地図を持つ [16] などの、高い計算・メモリコストが要求される。提案法は同様に RBPF を利用するが、RBPF により推定されるのは位置とクラスであり、さらにクラスは位置推定のための尤度計算と同じ計算ループで推定される。すなわち、各パーティクルがクラス分のメモリを持たない実装も容易であり、通常の PF による位置推定と比較して計算・メモリコストの増大を引き起こさずに、環境変化に対する推定の頑健性を向上させることができる。ただし、提案法は SLAM とは異なり地図を隠れ変数として扱わないため、根本的に環境の動的変化をモデリングして対応していないことには留意されたい。

地図更新を行わずに、異なる時間尺度の地図を用いて位置推定を行う方法も提案されている。Meyer-Delius らや, Valencia らは、短期・長期メモリ地図、すなわちオンラインとオフラインで構築した地図を併用する方法を提案している [17] [18]。この方法は、準動的障害物を利用して位置推定を行うことが可能とするが、オンラインでの地図構築が失敗した場合に、位置推定も失敗するという問題を含む。

Yang らは、静的・動的障害物を考慮した 2 種類の観測モデルを利用する方法を提案している [19]。Yang らの方法では、feasibility grids と呼ばれる地図データの活用法を提案している。これは、占有格子地図に feasibility という属性をもたせ、静止物体と移動物体を区別する方法である。提案法では、所与の幾何地図に加えた新たな地図情報は利用せず、3章

で後述する条件付き観測モデルを利用することで、未知障害物と位置の同時推定を実現する。

近年では、機械学習を用いて位置推定の失敗を検出する方法も提案されている [20] [21] [22] [23]。これらは、位置推定の正誤を End-to-End に学習することでセンサ観測と地図のミスマッチを暗に学習していると解釈でき、陽に未知障害物を検知しているとは言い難い。Kim らは、LiDAR の光学特性や未知障害物などを考慮しながら、事前に予測される観測と現在の観測を比較し、各観測に対してランドマークを観測する信頼度を推定する方法を提案している [24]。この方法は、未知障害物からの観測を検知することを可能とする点で提案法と類似の効果を持つといえるが、提案法は、位置と観測のクラスを同時推定しており、確率的に未知障害物を検知している点が異なる。

提案法と類似するグラフィカルモデルを提案している研究も存在する。Ting らは、センサ観測の背後に隠れ変数として重みを導入したモデルを提案し、この重みと隠れ状態をカルマンフィルタにより推定する方法を提案している [25]。この重みは、ロバスト推定における M 推定で利用される重みと等価の役割を果たし [26]、外れ値に対するフィルタリング性能のロバスト性を向上させている。Sarkka らは、センサ観測の背後に隠れ変数としてセンサノイズを導入したモデルを提案し、このノイズと隠れ状態を変分近似により推定する方法を提案している [27]。この方法は適応的にセンサノイズを推定するため、隠れ状態推定のための尤度計算をより正確に実行することを可能とさせる。一方で本稿では、センサ観測の背後に隠れ変数としてセンサクラスを導入したモデルを提案し、これを RBPF により推定する。本稿では、センサ観測のクラスとして地図上の存在の有無の 2 クラスを扱うが、これにより M 推定を適用したコスト関数と類似する観測モデルが導出される。これに関しては、4.3 節にて詳細を議論する。

### 3. 提案法

図 2 に、提案法において使用されるグラフィカルモデルを示す。本モデルでは、位置  $\mathbf{x}$  と観測物体のクラス  $\mathbf{c}$  が隠れ変数 (白色のノード) として扱われる。制御入力  $\mathbf{u}$  とセンサ観測  $\mathbf{z}$ 、地図  $\mathbf{m}$  は可観測変数 (灰色のノード) として扱われる。我々の目的は、以下に示す同時分布を求めることである。

$$p(\mathbf{x}_t, \mathbf{c}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) \quad (1)$$

ここで  $t$  と  $1:t$  は、現時刻と時系列のデータを表す。式 (1) に対して、まず乗法定理を適用する。

$$\begin{aligned} p(\mathbf{x}_t, \mathbf{c}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) \\ = p(\mathbf{x}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) p(\mathbf{c}_t | \mathbf{x}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) \end{aligned} \quad (2)$$

以下では、式 (2) 右辺の分布をそれぞれ展開していく。

まず式 (2) 右辺 1 つ目の分布に着目する。 $\mathbf{z}_t$  を用いてベイズの定理を適用し、次式を得る。

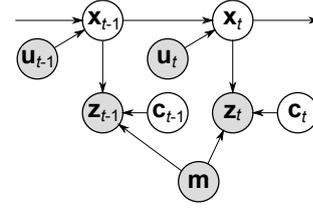


Fig. 2 The graphical model used in the proposed approach.

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) \\ = \eta p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) p(\mathbf{x}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) \end{aligned} \quad (3)$$

ここで  $\eta$  は正規化係数である。次に、式 (3) 右辺 1 つ目の分布の不必要な変数を除去 (条件付き独立性を考慮 [28])、2 つ目の分布に  $\mathbf{x}_{t-1}$  を用いて全確率の定理を適用する。

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) = \eta p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \\ \int p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) p(\mathbf{x}_{t-1} | \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) d\mathbf{x}_{t-1} \end{aligned} \quad (4)$$

ここで  $p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{m})$  は観測モデルである [2]。最後に、式 (4) 右辺 1 つ目の分布に  $\mathbf{c}_t$  を用いて全確率の定理を適用、2 つ目の分布から不必要な変数を除去し、次式を得る。

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) = \eta \int p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{m}) p(\mathbf{c}_t) d\mathbf{c}_t \\ \int p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t) p(\mathbf{x}_{t-1} | \mathbf{u}_{1:t-1}, \mathbf{z}_{1:t-1}, \mathbf{m}) d\mathbf{x}_{t-1} \end{aligned} \quad (5)$$

ここで  $p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{u}_t)$  は動作モデルである [2]。また  $p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{m})$  は、観測のクラス  $\mathbf{c}_t$  を条件として持つ観測モデルと解釈できるため「条件付き観測モデル」と呼ぶこととする。

次に、式 (2) 右辺 2 つ目の分布に着目する。 $\mathbf{z}_t$  を用いて、ベイズの定理を適用する。

$$\begin{aligned} p(\mathbf{c}_t | \mathbf{x}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) \\ = \eta p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) p(\mathbf{c}_t | \mathbf{x}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t-1}, \mathbf{m}) \end{aligned} \quad (6)$$

式 (6) からそれぞれ不必要な変数を除去し、次式を得る。

$$p(\mathbf{c}_t | \mathbf{x}_t, \mathbf{u}_{1:t}, \mathbf{z}_{1:t}, \mathbf{m}) = \eta p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{m}) p(\mathbf{c}_t) \quad (7)$$

これらの分布を用いて、式 (1) に示す同時分布を求める。

### 4. 実装

本論文では、式 (1) に示す同時分布を RBPF を用いて求める。具体的には、式 (5) に示す分布を PF で近似的に求め、式 (7) に示す分布を解析的に求める。以下には、実装に関する詳細を示す。

#### 4.1 変数定義

本論文では、2 次元の位置推定問題を対象とする。ロボットの状態  $\mathbf{x}$  は、位置  $x$ 、 $y$  と姿勢  $\theta$  とする。ロボットはエンコーダを所有しているとし、制御入力 (移動量)  $\mathbf{u}$  は並進方向

の移動量  $\Delta d$  と、角度方向の移動量  $\Delta\theta$  とする。

外界センサとしては、2次元のLiDARを想定する。すなわち、センサ観測は  $\mathbf{z} = ({}^1\mathbf{z}, {}^2\mathbf{z}, \dots, {}^K\mathbf{z})$  となり、 ${}^i\mathbf{z}$  は距離データ  ${}^il$  と角度データ  ${}^i\psi$  を含む。ここで  $K$  はセンサ観測の個数である。また、センサ観測のクラスは  $\mathbf{c} = ({}^1c, {}^2c, \dots, {}^Kc)$  とし、 ${}^ic$  は  ${}^i\mathbf{z}$  に対応したクラスである。センサ観測のクラスの種類は地図上での有無とし、 $C = \{\text{known}, \text{unknown}\}$  とする。なお時刻  $t$  における  $i$  番目のパーティクルの状態は  ${}^i\mathbf{s}_t = ({}^i\mathbf{x}_t, {}^i\omega_t)^T$  とする。ここで  ${}^i\omega_t$  はパーティクルの重みであり、次式で計算される。

$$\begin{aligned} {}^i\omega_t &= p(\mathbf{z}_t | {}^i\mathbf{x}_t, \mathbf{m}) {}^i\omega_{t-1} \\ {}^i\omega_t &\leftarrow \frac{{}^i\omega_t}{\sum_{j=1}^M {}^j\omega_t} \end{aligned} \quad (8)$$

$M$  はパーティクル数である。なお実装では、各パーティクルはクラス情報を保有しないが、クラスの計算方法に関しては4.5で述べる。

## 4.2 条件付き観測モデル

本論文では、センサ観測  $\mathbf{z}$  の各要素は独立していると仮定し、観測モデルを以下のように記述する。

$$p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) = \prod_{i=1}^K p({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \quad (9)$$

式(5)を導くために用いた式変形を用いて、提案法で使用される観測モデルは以下のように書き直される。

$$p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) = \prod_{i=1}^K \int p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t, \mathbf{m}) p({}^ic_t) d{}^ic_t \quad (10)$$

以下では、各条件が与えられた際の各観測に対する条件付き観測モデル  $p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t, \mathbf{m})$  について述べる。

knownのクラスが与えられた際のモデルとしては、LFMを利用する。

$$\begin{aligned} p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{known}, \mathbf{m}) \\ = \begin{pmatrix} z_{\text{hit}} \\ z_{\text{max}} \\ z_{\text{rand}} \end{pmatrix}^T \cdot \begin{pmatrix} p_{\text{hit}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \\ p_{\text{max}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \\ p_{\text{rand}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \end{pmatrix} \end{aligned} \quad (11)$$

ここで  $z_{\text{hit}}$ ,  $z_{\text{max}}$ ,  $z_{\text{rand}}$  は任意の係数であり、 $z_{\text{hit}} + z_{\text{max}} + z_{\text{rand}} = 1$  を満たす。またこれらの値は、静的環境下におけるセンサ観測を考慮しながら経験的  $z_{\text{hit}} = 0.9$ ,  $z_{\text{max}} = 0.05$ ,  $z_{\text{rand}} = 0.05$  と設定した。さらに  $p_{\text{hit}}(\cdot)$ ,  $p_{\text{max}}(\cdot)$ ,  $p_{\text{rand}}(\cdot)$  はそれぞれ、センサ観測がランドマークに当たる、最大の観測値を得る、およびランダムな観測を得る確率分布であり、それぞれ以下のように定められる。

$$p_{\text{hit}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{d(\mathbf{q}(\mathbf{x}_t, {}^i\mathbf{z}_t), \mathbf{m})^2}{2\sigma^2}\right) \quad (12)$$

$$p_{\text{max}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) = \begin{cases} 1 & \text{if } {}^il \geq L \\ 0 & \text{otherwise} \end{cases} \quad (13)$$

$$p_{\text{rand}}({}^i\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) = \text{unif}(0, L) \quad (14)$$

ここで  $\sigma$  は観測に対する誤差の標準偏差、 $\mathbf{q}(\cdot)$  はスキャン点の地図上の座標を返す関数、 $d(\cdot)$  は地図上の点から最も近いランドマークまでの距離を返す関数、 $L$  はセンサの最大の計測距離、 $\text{unif}(\cdot)$  は与えられた区間における一様分布である。

unknownのクラスが与えられた際のモデルは、以下の様に定義する。

$$\begin{aligned} p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{unknown}, \mathbf{m}) \\ = \eta \left( \max_{\text{known}} - p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{known}, \mathbf{m}) \right) \end{aligned} \quad (15)$$

ここで  $\max_{\text{known}}$  は、 $p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{known}, \mathbf{m})$  の最大値である。上式は、ランドマークが存在する地点以外で、一様に障害物が観測されることを想定した分布となっている。

最終的に、提案法では以下の観測モデルを利用する。

$$\begin{aligned} p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \\ = \prod_{i=1}^K \left( p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{known}, \mathbf{m}) p({}^ic_t = \text{known}) \right. \\ \left. + p({}^i\mathbf{z}_t | \mathbf{x}_t, {}^ic_t = \text{unknown}, \mathbf{m}) p({}^ic_t = \text{unknown}) \right) \end{aligned} \quad (16)$$

上述の通り、提案法ではBMの様に、1つの観測モデルですべての観測に関する事象を説明しようとせず、複数のクラスがあることを前提として、それぞれのセンサ観測のクラスが条件付けられた下で、各々のクラスに対する観測のモデル化を行う。そのため、複雑な環境変化を考慮した実装を排除することができる。またこれにより、環境変化へのロバスト性を向上させながら、計算の高速化を行うことが可能となる。

図3には、提案法、LFM、およびBMを観測モデルとして使用した際の尤度分布の比較を示す。提案法による分布の特徴は、ランドマーク付近(15 m)以外での観測可能な範囲全体に対して、一様な観測確率が現れることである。これは、観測可能範囲すべてで、未知の動的障害物を観測する可能性があるということを意味する(注1)。一方でBMでは、ランドマーク前方までの範囲で、観測確率があると仮定されている。すなわち提案法は、ランドマークの移動や削除などにより、ランドマーク後方から観測が得られる状況にも対応することができる。加えて提案法による分布は、ランドマークの存在する地点で観測確率が最も高くなり、かつその付近では尤度が減少する。すなわち、位置推定の失敗によるセンサ観測と地図の照合の失敗に対して、尤度を下げることができる。

一方で、上記の利点は異なる欠点を招くことにもなる。これに関しては5.4で議論する。

## 4.3 M推定との関連

最小二乗法などによりデータに適合する値を推定する際、単純にすべてのデータを同等に利用してコスト関数を作成すると外れ値に対して脆弱になる。この解決策として、ロパス

(注1) LFMやBMにおいても  $p_{\text{rand}}(\cdot)$  が含まれるため、観測可能範囲全体で観測が得られる可能性を表現しているが、提案法ではより陽に未知障害物の観測可能性を仮定している。

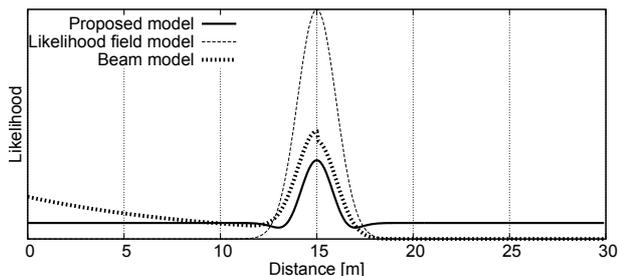


Fig. 3 Comparison of likelihood distributions. A landmark locates at where distance is 15 m.

ト推定法が提案されており、その 1 つに  $M$  推定がある [26].  $M$  推定では、残差  $\delta$  に対して反比例する重みを導入することで、大きな残差を有するデータがコスト関数上で無視される。 $M$  推定の 1 種である Blake-Zisserman では、正対応の残差は正規分布、外れ値の分布は一様分布に従うと仮定しており、そのコスト関数  $C(\delta)$  は以下の様に表現できる [29].

$$C(\delta) = -\log(\exp(-\delta^2) + \epsilon) \quad (17)$$

ここで  $\epsilon$  は一様分布に従うノイズである。

上式対数内部は確率分布と解釈することもできる (注 2). 動的環境で観測モデルを考える際には、地図に存在しない未知物体からの観測も考慮されなければならない。提案法では、未知物体からの観測のモデルを、地図上の物体以外から一様に観測されると仮定している (式 (15)). そしてこのモデルを条件付き観測モデルを用いて統合することで、図 3 に示すモデルが導出される。すなわちこのモデルは、未知物体からの観測も一様分布に従う外れ値であると明示的に考慮しており、 $M$  推定におけるコスト関数と類似すると解釈できる。

#### 4.4 センサ観測のクラス推定

4.2 節で述べた通り、センサ観測の各要素が独立であるという仮定を用いると、式 (7) は以下の様に書き換えられる。

$$p(\mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{m}) p(\mathbf{c}_t) = \prod_{i=1}^K p(i | \mathbf{z}_t | \mathbf{x}_t, \mathbf{c}_t, \mathbf{m}) p(i | \mathbf{c}_t) \quad (18)$$

この分布を推定するために、クラスに関する事前分布  $p(i | \mathbf{c}_t)$  を定める必要がある。しかしながら提案法において、事前分布を何かしらの情報に従って定めることはできない。そのため各クラスの確率は等しいと仮定し、 $p(i | \mathbf{c}_t = \text{known}) = p(i | \mathbf{c}_t = \text{unknown}) = 0.5$  とする。尤度計算に関しては、式 (11) と (15) を使用する。

#### 4.5 RBPF の計算手順

実装では、式 (18) に示す分布を計算した後に、式 (10) に示す分布を計算する。これらの分布は、同一の計算ループ内で計算されるため、提案法の計算量は LFM と等しくなる。

その後、式 (8) を用いてパーティクルの尤度計算を行い、尤度を正規化する。そして、パーティクルの位置に対する重み付き平均を計算し、それを推定位置  $\mathbf{x}_t$  とする。パーティク

ルの尤度計算を終え、最尤パーティクルが得られた後に、最尤パーティクルの位置とセンサ観測を用いて、再度クラス推定のみを行い、クラスに関する値を得る。この処理は、パーティクル数 +1 回分の尤度計算を要求することとなるが、各パーティクルにおけるクラス分のメモリ使用量を削減することができる。また、尤度計算は LFM とほぼ等価の計算コストで実現できるため、計算コストも実用上問題にならないといえる。最後に、有効サンプル数  $1/\sum_{i=1}^M \omega_t^2$  を計算し、これが  $M/2$  を下回った場合にリサンプリングを行う。ここで  $M$  はパーティクル数であり、 $M = 200$  とした。

## 5. 実験

### 5.1 プラットフォーム

本実験では、2次元 LiDAR およびオドメトリに関するシミュレータを用いる。移動機構は左右独立 2 輪駆動系とし、時刻  $t-1$  から  $t$  のロボットの状態は以下の様に更新される。

$$\begin{pmatrix} x_t \\ y_t \\ \theta_t \end{pmatrix} = \begin{pmatrix} x_{t-1} \\ y_{t-1} \\ \theta_{t-1} \end{pmatrix} + \begin{pmatrix} \Delta d_t \cos \theta_{t-1} \\ \Delta d_t \sin \theta_{t-1} \\ \Delta \theta_t \end{pmatrix} \quad (19)$$

また 2次元センサとしては、北陽電機社製の UTM-30LX (注 3) を再現した。具体的な仕様は、測定距離 30 m、観測角度 270 度、角度分解能 0.25 度である。シミュレーションでは、エンコーダによる観測  $\Delta d$ ,  $\Delta \theta$ , および LiDAR の各距離情報  $l$  に対して、任意の分散を有するガウス分布に従うノイズを加える。またエンコーダの観測に対しては、任意のバイアスを加える。なお、計測範囲に存在する物体の観測の失敗に関しては、本実験では考慮していない。

### 5.2 未知障害物の棄却アルゴリズム (比較法)

文献 [2] では、未知障害物を観測している可能性の高いデータを棄却する方法が述べられており、その方法では次式が利用されている。

$$\frac{\int z_{\text{short}} p_{\text{short}}(i | \mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \overline{\text{bel}}(\mathbf{x}_t) d\mathbf{x}_t}{\int p_{\text{beam}}(i | \mathbf{z}_t | \mathbf{x}_t, \mathbf{m}) \overline{\text{bel}}(\mathbf{x}_t) d\mathbf{x}_t} > \chi \quad (20)$$

ここで  $z_{\text{short}}$  は任意の係数、 $p_{\text{short}}(\cdot)$  はランドマークより前方から観測値を得る状態を示した確率分布、 $p_{\text{beam}}(\cdot)$  は BM である (詳細は文献 [2] に譲る)。また  $\overline{\text{bel}}(\cdot)$  は、運動モデルにより更新されたロボット位置に関する存在確率を表す分布であり、 $\chi$  は 0 から 1 の閾値である。実装では、 $\overline{\text{bel}}(\cdot)$  はパーティクル分布により近似される。本論文では、この未知障害物の棄却アルゴリズムを rejection method (RM) と表記する。

RM は、パーティクルの尤度計算を行う前に実行される。すなわち、未知障害物を無視して位置推定を行うことを目的としたものである。実験では、RM と提案法の比較を行う。閾値  $\chi$  は 0.9 とし、同様に提案法においても  $p(i | \mathbf{c}_t = \text{unknown}) > 0.9$  となったセンサ観測を未知障害物として認識することとする。

(注 2) 実際に確率分布とするためには正規化が必要である。

(注 3) <https://www.hokuyo-aut.co.jp/search/single.php?serial=21>, 2018 年 9 月 27 日にアクセス。

### 5.3 シミュレーション実験

ある屋内環境にて実機を用いた SLAM [16] を行い、これにより構築された地図を用いて LiDAR の観測値をシミュレートした。このシミュレーション用地図から、ランドマークをランダムに 70 % 除去し、かつ地図上で多数のランダムウォークする障害物をシミュレートした環境 (図 1) で実験を行うことで、提案法の環境の動的変化に対する頑健性を検証する。なお動的障害物は約 30 体シミュレートし、その形状は正方形とし、サイズはランダムに選択した。

本実験では、敢えて現実には存在しない様な過酷な環境を再現している。当然ながら、環境変数は膨大であり、条件の統一が困難である。そのため、ある環境で性能が検証できたとしても、他の環境で同様の性能が得られる保証はない。そこで、敢えて過酷な環境で検証を行うことで、他の一般的な環境における安定性を定性的に示すことを目的とし、過酷な環境を再現して実験を行った。

#### 5.3.1 位置推定実験

図 4 には、提案法 (上図) および RM を用いた LFM (下図) による位置推定の結果をそれぞれ示す。各左図において、Simulation map は LiDAR の観測値のシミュレーション用地図を示す。Known objects, および Unknown objects は、それぞれの方法により地図上に存在する観測、および存在しない観測であると判断されたセンサ観測である。Ground truth, Estimated trajectory, および Odometry は、それぞれ真値、位置推定結果、およびオドメトリの軌跡である。提案法は、ランドマーク周辺の観測を地図上に存在する観測と認識しているが、RM はランドマークの後方に存在する観測も地図上に存在する観測と認識している。これは、BM に基づく RM が、ランドマークの除去・移動に対応していないためである。

各右図上は、センサがランドマークを観測している割合、および地図上に存在する観測かどうかを分類した精度を示している。ランドマークの観測割合は、どちらのケースでも 20 % 程度であり、シミュレーション環境が高い動的状態であったといえる。提案法は、RM よりも高い精度で観測のクラスを分類していることが確認できる。また各右図下は、推定位置と真値間の位置誤差、および角度誤差をそれぞれ示している。提案法の方が、推定誤差が小さいという結果が得られた。

提案法の結果から、時刻 60 秒の辺りで位置推定の誤差が増加していることが確認できる。この瞬間は、パーティクルのリサンプリングが行われずに、パーティクルの分布が膨張し、かつ尤度計算に失敗した例である。この際、パーティクルの分布が疎になっていたとはいえ、これはパーティクル数の増加により解決できる問題とは言い難い。そのためこの例は「すべての動的状況下で提案法による尤度計算が上手く行われるわけではない」という、提案法の限界を表した一例となっている。しかしながら、提案法におけるその様な状況の発生確率は、LFM を用いた手法と比較して少ない結果となっている。

なお、紙面の都合上実験環境は 1 つとなっているが、実際

には実環境を含む複数の環境下で同様の結果が得られることを確認している。

#### 5.3.2 クラス認識精度検証

5.2 節で述べたように、RM による認識の精度はパーティクルの分布に依存する<sup>(注 4)</sup>。図 5 には、パーティクルの分布幅の増大に伴う観測クラスの認識精度の変化を示す。本実験では、パーティクルを非対角成分がゼロの共分散行列に従う正規分布を用いて生成しており、横軸はその共分散行列のトレースを示す。なお、角度成分に関する分散はゼロとしているが、これはトレースの数値的意味を物理的に理解し易いものとするためであり、角度成分が非ゼロであっても同様の結果が得られることに留意されたい。また前述の通り、RM はランドマークの除去・移動には対応できないため、今回はランドマークの除去は行わず、前述の実験と同様の動的障害物のみのシミュレーションを行った。

RM は、トレースの増加、すなわちパーティクルの分布幅の増大に伴い、認識の精度が低下していることが確認できる。これは、分布幅が大きい場合に、ランドマーク周辺で観測した未知物体を棄却できなかったためである。一方で提案法は、分布の状況に依存せず、ほぼ一定の認識精度となった。これは、提案法が位置と観測のクラスを同時に推定するため、パーティクルの分布幅に依存せずに真値周辺のパーティクルが最尤となり、その最尤パーティクルによる認識結果が利用されるためである。

#### 5.3.3 計算時間

表 1 には、パーティクル数の増加に伴う尤度計算時間の比較を行った結果を示す。なお使用した CPU は Intel(R) Xeon(R) CPU E5-1650 v3@3.50 GHz であり、それぞれの計算はシングルスレッドで行った。最も計算時間が速いのは、RM を用いない LFM である。しかし RM を用いない LFM は、未知障害物の影響を容易に受け、位置推定に失敗しやすい。最も正確かつロバストな位置推定が可能なものは、RM を用いた BM であると言えるが、パーティクル数が増加すると、リアルタイムでの計算が困難といえる計算時間となる。また RM を用いた LFM も、RM の計算を行うために BM の計算を行う必要があるため、RM を用いない BM と同等の計算時間となる。

一方で提案法は、RM を用いない LFM とほぼ同程度の計算時間となった。これは、提案法と LFM の計算量が等しいためである。わずかに提案法の計算量が増えているのは、クラス観測を推定する計算が含まれるためであるが、BM や RM 等と比較して、実時間性に関して大きな問題となることはないといえる。なお、すべての手法は同一の地図を用いて計算を行っているため、地図のために要求されるメモリコストはそれぞれ同一である。またクラス  $c$  はパーティクルに保有させない実装方法も可能である (その場合には  $M + 1$  回の尤度

(注 4) 分布に依存しない実装方法も考えられるが、その場合にはパーティクルの位置や尤度を考慮したクラスタリング、特にクラスタ数が未知な状態での複雑なクラスタリングが必要となる。

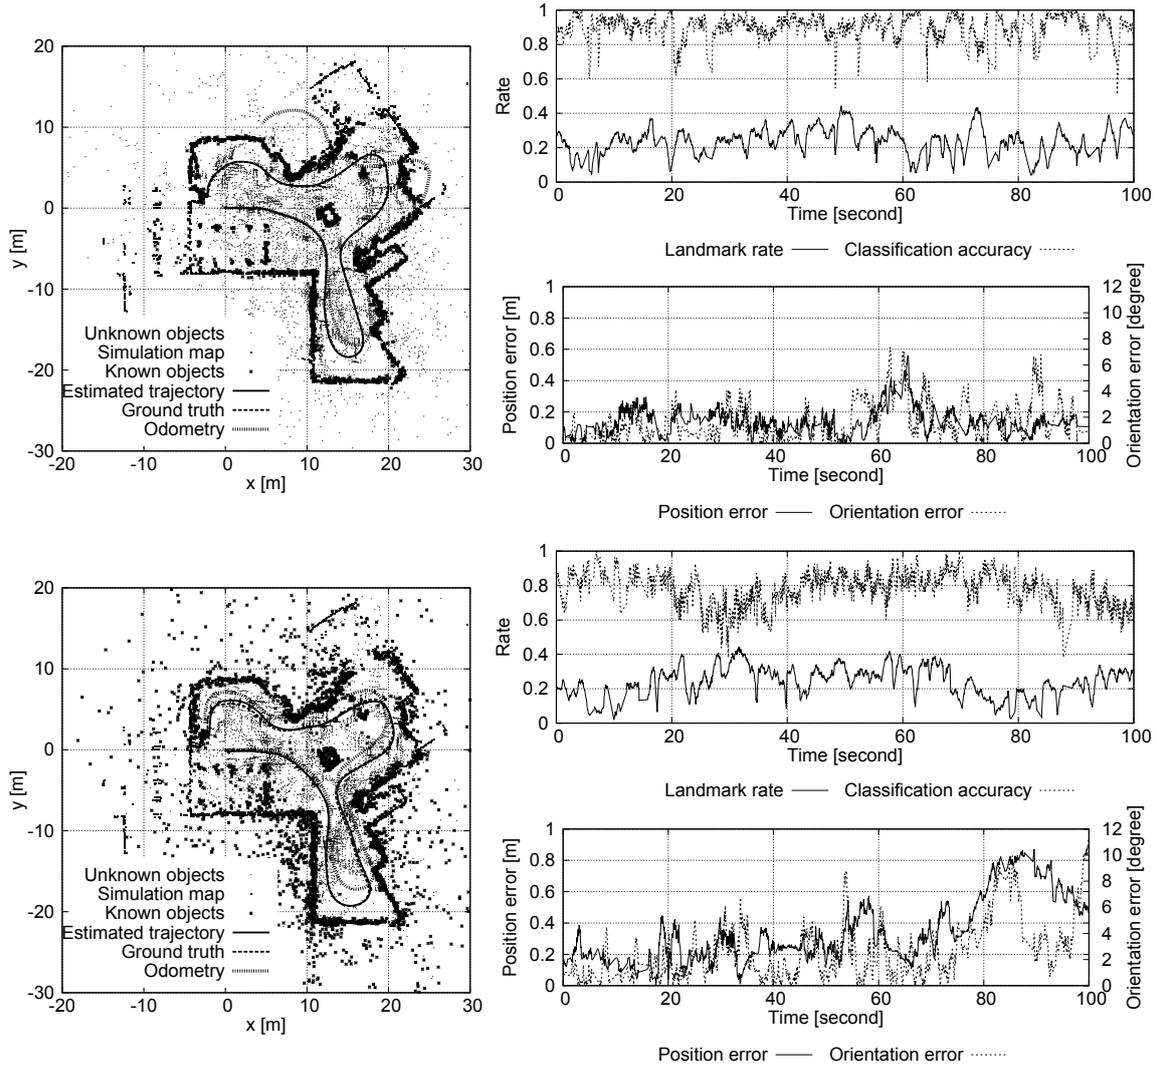


Fig. 4 Localization results by the proposed approach (top) and LFM with the RM (bottom).

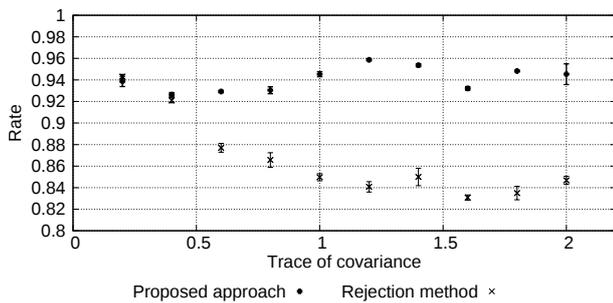


Fig. 5 Comparison of classification accuracy of known and unknown objects.

計算が要求される) ため、提案法が各パーティクルに要求するメモリコストも他の手法と同等である。なお、表1に示す提案法の計算時間は、この方法による計算時間を示している。これらの結果から、提案法が計算量を増大させることなく、環境変化に対する位置推定のロバスト性を向上させることがで

きることを確認できた。

#### 5.4 利点と性能限界

BMを用いた位置推定は、多くの場合高精度に機能する。特にRMを用いることで、動的環境においても非常に良く機能する。しかしBMには、前述の計算コストの問題以外に、未知障害物を観測する確率とランドマークを観測する確率の重み、すなわち  $z_{\text{short}}$  と  $z_{\text{hit}}$  がEMアルゴリズムなどを用いてデータドリブンに決定される必要がある [2] という問題がある (注5)。当然ながら、ある環境における未知障害物の量を事前予測することは困難であり、各環境において必ずしも適切なパラメータを用いて位置推定を行えているとは言い難い。一方で提案法は、未知障害物の量を事前予測するという作業を必要としない。これは、図3からわかるように、提案法はセンサ観測が得られる範囲全体で、一様に観測が得られる可能性があるということを仮定しているためである。

(注5)  $z_{\text{max}}$  と  $z_{\text{rand}}$  もデータドリブンに推定されるべきパラメータではあるが、影響は前述の2つに比べて小さいといえる。

**Table 1** Average and standard deviation of computation times in millisecond for calculating likelihood.

# of particles	100	200	300	400	500
Proposed approach	2.81 (1.05)	4.82 (1.58)	9.06 (2.78)	10.14 (3.27)	12.63 (3.95)
LFM without RM	2.65 (0.90)	5.04 (1.42)	6.39 (1.97)	7.46 (2.33)	9.36 (3.20)
LFM with RM	23.97 (5.26)	42.31 (4.20)	61.43 (2.86)	81.39 (3.06)	101.39 (1.74)
BM without RM	19.47 (0.89)	38.84 (3.08)	58.25 (6.02)	78.70 (9.13)	98.02 (9.37)
BM with RM	38.44 (3.37)	76.45 (4.47)	115.16 (11.22)	153.53 (11.50)	198.22 (24.96)

しかし、上述の仮定は異なる問題を招く。一般に LiDAR のように放射状に広がるセンサの場合、センサ付近の方が観測が得られる確率は高い。BM は、このような特性を考慮したモデルとなっているが、それを実現するためにレイキャストを実効して計算量の増加を招いている。提案法では、上述の様な仮定を設けることで、計算の高速化や、ランドマーク除去・移動などの環境変化への対応を実現しているが、その一方で、真値から離れた地点の尤度も増加する傾向が出てしまう。これは、観測範囲全てで一定の未知障害物が観測される可能性があるということを仮定しているために、大きくミスマッチした事象を、未知障害物を観測している事象として解釈して起きてしまう問題である。すなわち提案法は、初期位置誤差が大きい様な大極的位置推定問題などに対して不向きである。一方で、位置追跡問題を解くにあたっては、ロバスト性を向上させる方に寄与することができる。このような性能も、M 推定と同様の性能であると判断できる。

提案法の性能の理解の一助のために、以下のシミュレーションおよび実環境実験の動画を参考にされたい<sup>(注6)</sup>。実環境における実験では、車体の振動やマッピングの不確かさから地図上に存在しない観測が得られるシーンが見られたが、そのような観測を未知障害物からの観測と識別し、ロバストに位置推定が行えていることが確認できた。

## 6. おわりに

本論文では、自己位置とセンサ観測のクラスを同時推定する方法を提案した。なおここでのクラスとは、幾何地図上での観測物体の有無を表す。提案法は、Rao-Blackwellized particle filter (RBPF) を用いて実装されており、センサ観測のクラスを解析的に求め、ロボット位置を PF により推定している。提案法を用いることで、地図上に存在する障害物から得られているセンサ観測のみを有効利用し、ロボット位置を推定できる。結果として、動的障害物やランドマークの移動・除去に関する環境変化に対して、頑健に位置推定ができることを確認した。また提案法は、likelihood field model や beam model [2] などの従来法と比較し、計算・メモリコストを増大させることなく、ロバスト性を向上させることを示した。

今後は、より多くのクラスを考慮した位置推定、すなわちセマンティック地図を活用した位置推定に向けて提案法を拡張する予定である。そして、セマンティクスの活用が、地図

上での有無の考慮のみと比べて、どの様な点で優れるかなどを明らかにしていく。また、これまでに提案してきた位置推定結果に対する信頼度の推定法 [22] [23] と提案法を統合する枠組みの提案を行う予定である。

謝辞 本研究は、JST, COI, JPMJCE1317, 科研費 40786092, および人工知能研究振興財団の支援により行われた。

## 参考文献

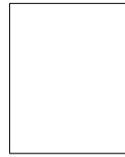
- 1) P. J. Besl and N. D. McKay. A method for registration of 3-D shapes. *IEEE Trans. on Pattern Anal. Mach. Intell. (TPAMI)*, 14(2):239–256, Feb. 1992.
- 2) S. Thrun, W. Burgard, and D. Fox. *Probabilistic Robotics*. 2005.
- 3) D. Fox, W. Burgard, and S. Thrun. Markov localization for mobile robots in dynamic environments. *J. of Artif. Intelligence Res. (JAIR)*, 11(1):391–427, Jul. 1999.
- 4) W. Burgard, A. B. Cremers, D. Fox, D. Hähnel, G. Lake-meyer, D. Schulz, W. Steiner, and S. Thrun. Experiences with an interactive museum tour-guide robot. *Artif. Intell.*, 114:3–55, 1999.
- 5) N. Akai, L. Y. Morales, E. Takeuchi, Y. Yoshihara, and Y. Ninomiya. Robust localization using 3D NDT scan matching with experimentally determined uncertainty and road marker matching. In *Proc. of the IEEE Intell. Vehic. Symp. (IV)*, pages 1357–1364, 2017.
- 6) N. Akai, L. Y. Morales, T. Yamaguchi, E. Takeuchi, Y. Yoshihara, H. Okuda, T. Suzuki, and Y. Ninomiya. Autonomous driving based on accurate localization using multilayer LiDAR and dead reckoning. In *Proc. of the IEEE Int. Conf. on Intell. Transp. Syst. (ITSC)*, pages 1147–1152, 2017.
- 7) S. Olufs and M. Vincze. An efficient area-based observation model for Monte-Carlo robot localization. In *Proc. of the IEEE/RSJ Int. Conf. on Intell. Rob. and Syst. (IROS)*, pages 13–20, 2009.
- 8) E. Takeuchi, K. Ohno, and S. Tadokoro. Robust localization method based on free-space observation model using 3d-map. In *Proc. of the IEEE Int. Conf. on Rob. Bio. (ROBIO)*, pages 973–979, 2010.
- 9) D. Wang, J. Xue, T. Zhongxing, Y. Zhong, D. Cui, S. Du, and N. Zheng. Accurate mix-norm-based scan matching. In *Proc. of the IEEE/RSJ Int. Conf. on Intell. Rob. and Syst. (IROS)*, pages 1665–1671, 2018.
- 10) N. Akai, L. Y. Morales, T. Hirayama, and H. Murase. Toward localization-based automated driving in highly dynamic environments: Comparison and discussion of observation models. In *Proc. of the IEEE Int. Conf. on Intell. Transp. Syst. (ITSC)*, pages 2215–2222, 2018.
- 11) S. Brechtel, T. Gindele, and R. Dillmann. Recursive importance sampling for efficient grid-based occupancy filtering in dynamic environments. In *Proc. of the IEEE Int. Conf. on Rob. and Autom. (ICRA)*, 2010.

(注6) <https://drive.google.com/drive/u/0/folders/1yvC3mfZunXsogoLoTFmEdhvBr6PdH48G>

- 12) D. Meyer-Delius, M. Beinhofer, and W. Burgard. Occupancy grid models for robot mapping in changing environments. In *Proc. of the AAAI Conf. on Artif. Intell. (AAAI)*, pages 2024–2030, 2012.
- 13) J. Saarinen, H. Andreasson, and A. J. Lilienthal. Independent Markov chain occupancy grid maps for representation of dynamic environments. In *Proc. of the IEEE/RSJ Int. Conf. on Intell. Rob. and Syst. (IROS)*, 2012.
- 14) C.-C. Wang, C. Thorpe, S. Thrun, M. Hebert, and H. Durrant-Whyte. Simultaneous localization, mapping and moving object tracking. *Int. J. of Rob. Res. (IJRR)*, 26(9):889–916, Sep. 2007.
- 15) G. D. Tipaldi, D. Meyer-Delius, and W. Burgard. Lifelong localization in changing environments. *Int. J. of Rob. Res. (IJRR)*, 32(14):1662–1678, 2013.
- 16) G. Grisetti, C. Stachniss, and W. Burgard. Improved techniques for grid mapping with Rao-Blackwellized particle filters. *IEEE Trans. on Rob. (TRO)*, 23(1):34–46, Feb. 2007.
- 17) D. Meyer-Delius, J. Hess, G. Grisetti, and W. Burgard. Temporary maps for robust localization in semi-static environments. In *Proc. of the IEEE/RSJ Int. Conf. on Intell. Rob. and Syst. (IROS)*, pages 5750–5755, 2010.
- 18) R. Valencia, J. Saarinen, H. Andreasson, J. Vallvé, J. Andrade-Cetto, and A. J. Lilienthal. Localization in highly dynamic environments using dual-timescale NDT-MCL. In *Proc. of the IEEE Int. Conf. on Rob. and Autom. (ICRA)*, pages 3956–3962, 2014.
- 19) S.-W. Yang and C.-C. Wang. Feasibility grids for localization and mapping in crowded urban scenes. In *Proc. of the IEEE Int. Conf. on Rob. and Autom. (ICRA)*, pages 2322–2328, 2011.
- 20) H. Almqvist, M. Magnusson, T. Kucner, and A. J. Lilienthal. Learning to detect misaligned point clouds. *Int. J. of Field Rob. (JFR)*, 35(5):662–677, 2018.
- 21) S. Nobili, G. Tinchev, and M. Fallon. Predicting alignment risk to prevent localization failure. In *Proc. of the IEEE Int. Conf. on Rob. and Autom. (ICRA)*, pages 1003–1010, 2018.
- 22) N. Akai, L. Y. Morales, and H. Murase. Reliability estimation of vehicle localization result. In *Proc. of the IEEE Intell. Vehic. Symp. (IV)*, pages 740–747, 2018.
- 23) N. Akai, L. Y. Morales, and H. Murase. Simultaneous pose and reliability estimation using convolutional neural network and Rao-Blackwellized particle filter. *Adv. Rob.*, 32(17):930–944, Aug. 2018.
- 24) J. Kim and W. Chung. Robust localization of mobile robots considering reliability of LiDAR measurements. In *Proc. of the IEEE Int. Conf. on Rob. and Autom. (ICRA)*, pages 6491–6496, 2018.
- 25) J. Ting, E. Theodorou, and S. Schaal. A Kalman filter for robust outlier detection. In *Proc. of the IEEE/RSJ Int. Conf. on Intell. Rob. and Syst. (IROS)*, pages 1514–1519, 2007.
- 26) J. Fox and S. Weisberg. Robust regression. *School of Statistics: University of Minnesota*, 2013.
- 27) S. Sarkka and A. Nummenmaa. Recursive noise adaptive Kalman filtering by variational Bayesian approximations. *IEEE Trans. on Automatic Control*, 54(3):596–600, 2009.
- 28) C. M. Bishop. *Pattern Recognition and Machine Learning*. Springer-Verlag, 2006.
- 29) R. Hartley and A. Zisserman. *Multiple View Geometry in Computer Vision*. Cambridge University Press, New York, NY, USA, 2 edition, 2003.

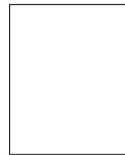
## [著者紹介]

## 赤井直紀 (正会員)



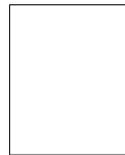
2016年宇都宮大学大学院システム創成工学専攻博士後期課程終了。博士(工学)。同年名古屋大学未来社会創造機構特任助教, 2019年より名古屋大学大学院情報学研究科知能システム学専攻特任助教。現在に至る。車輪型移動ロボットおよび自動車の自動走行, 特に自己位置推定に関する研究に従事。SII2013 Best Student Paper Award, JSAE2018 秋季大会優秀講演発表賞などを受賞。IEEE, SICE, RSJ, JSME 各会員。

## モラレス ルイス 洋一



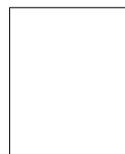
2006年筑波大学大学院修士課程修了。2009年同大学院博士課程修了後。博士(情報学)。同年半年間筑波大学の研究員を経て, ATR 知能ロボティクス研究所研究員。2016年名古屋大学未来社会創造機構特任准教授。現在に至る。自動走行及び運転を専門としたフィールドロボティクスに関する研究に従事。一貫して屋内外の環境での自動走行, また搭乗員の快適なナビゲーションの研究に取り組む。IEEE, IEEE-RAS, 日本ロボット学会各会員。

## 平山高嗣



1998年奈良高専情報工学科卒業。2000年金沢大学工学部電気情報工学科卒業。2005年大阪大学大学院基礎工学研究科博士後期課程修了。博士(工学)。同年より京都大学大学院情報科学研究科特任助教。2011年より名古屋大学大学院情報科学研究科特任助教。2012年より同助教。2014年より同特任准教授。2017年より名古屋大学未来社会創造機構特任准教授。現在に至る。画像認識, 視行動分析, 視覚的注意の計算モデルに関する研究に従事。2009年ヒューマンインタフェース学会論文賞, ACM ETRA2014 Best Short Paper Award, IEEE ISM2014 Best Paper Award, 2014年電子情報通信学会情報・システムソサイエティ論文賞受賞。電子情報通信学会, 情報処理学会, IEEE, ACM 各会員。

## 村瀬 洋



1978年名古屋大学工学部電気工学科卒, 1980年同大学院修士課程修了。同年日本電信電話公社(現在のNTT)武蔵野電気通信研究所に入所。1992年から1年間米国コロンビア大学客員研究員。2003年より名古屋大学大学院情報科学研究科教授。2017年から同大学院情報学研究科教授。一貫して, 画像・映像認識, コンピュータビジョンの研究に従事。工学博士。1994年IEEE CVPR 最優秀論文賞, 2001年高柳記念奨励賞, 2002年電子情報通信学会業績賞, 2003文部科学大臣賞, 2004年IEEE論文賞(Trans. MM), 2010年前島密賞, 2018年電子情報通信学会功績賞, 他受賞。2012年紫綬褒章を受章。IEEE Fellow, 電子情報通信学会フェロー, 情報処理学会フェロー。