自律移動ロボットのロバストな位置推定のための 相関係数による多数決センサ選択と統合

大 橋 臨*・舟 洞 佑 記*
道 木 慎 二*・道 木 加 絵**

Majority Rule Based Sensor Fusion System with Correlation Evaluation for Mobile Robot Localization

Nozomu OHASHI*, Yuki FUNABORA*,
Shinji DOKI* and Kae DOKI**

Robustness of localization is a crucial issue for a mobile robot moving in various kind of environment. We have researched a robust localization system with various characteristic sensors. In past research, we proposed a selective sensor fusion system with majority rule; representing each sensor's robot position as a probability distribution, evaluating similarities between probability distributions, and selecting probability distributions based on majority rule. Although the effectiveness of the selective sensor fusion system was experimentally confirmed, proper selection could not be done in some case because similarity evaluation had a problem. This paper proposes up-to-date system to conduct more proper sensor selection. Simulational and experimental results show that the proposed system can select proper sensors in various environment.

Key Words: probabilistic localization, sensor fusion, similarity evaluation

1. はじめに

センサ情報を基に自身の位置を推定する自己位置推定技術は、自動車、スマートホン、自律移動ロボットなどを対象に広く研究されている^{1)~17)}。例として、自律移動ロボットでは、地図構築、経路生成、障害物回避などの移動の要素技術に推定した位置情報を用いる^{18), 19)}。GPS、カメラ、レーザスキャナなどのさまざまなセンサを用いた位置推定法が提案されている^{1)~10)}が、特に人の生活環境内では、個々のセンサに依る位置推定法の精度が環境に依存して低下する点が問題になる。たとえば、GPSを用いた位置推定では、ビルなどの障害物からの反射波の影響を受ける市街地環境下などで位置推定が破綻する場合がある。カメラやレーザスキャナの場合も、見通しの良い環境では位置推定に有用な特徴が得難く、単一のセンサでは適用可能な環境に限界があった。

そこで、特性の異なる複数のセンサを併用し、位置情報を統

合することで位置推定のロバスト化を図る研究が注目されている^{10)~17), 19)~21)}。移動ロボットの位置推定における位置情報統合法は、一般的に2つの方策をとっている。1つ目は、移動環境下で有用なセンサ組合せを設計者が事前に割り当てて統合する手法¹⁹⁾である。センサの特性や設計者の経験・知見に沿った選択ができる一方で、移動環境の拡大に伴い設計者への負担が増加する。加えて、実環境下では、設計したセンサ割り当てが永続的に機能する保証がなく、結局のところ適用可能な環境は限定される。2つ目は、センサごとに算出した推定位置と信頼性を基に統合する手法^{15)~17)}である。たとえば、文献17)では、GPSと加速度・ジャイロ・磁気方位センサを統合する際に、各センサの推定値に加え、その信頼性として推定誤差共分散行列を導入し、カルマンフィルタにより統合している。ここで、GPSの推定誤差共分散行列は、観測衛星数や衛星配置により決まる測位精度低下率(DOP値)から求める。GPS誤差円にも利用されるDOP値は、一般的にGPSの信頼性の指標とされるが、マルチパスエラーの影響は反映できず、たとえDOP値が低くても位置推定誤差は大きい場合がある。センサごとに信頼性の算出法は研究されている^{1), 14)}ものの、センサや環境への依存性が高く、一般的な手法の確立には至っていない。

以上を踏まえ、異なる観点の統合法として、著者らは、特性の異なる複数センサの位置情報を相対的に評価して選択的に

* 名古屋大学大学院工学研究科 名古屋市千種区不老町

** 愛知工業大学工学部 豊田市八草町 1247

* Graduate School of Engineering, Nagoya University,
Furo-cho, Chikusa-ku, Nagoya

** Faculty of Engineering, Aichi Institute of Technology,
1247 Yakusa-cho, Toyota

(Received January 9, 2019)

(Revised April 4, 2019)

Fig. 1 Sensor fusion system with relative evaluation

統合する手法の可能性を検討してきた¹²⁾。先の2つの方策とセンサ間の相互評価を組み合わせることで、不確定要素の多い人の生活環境内でもロバストに位置推定することを目論む。これまでに、センサ間の相互評価に限定した場合でのロバスト性向上の可能性を検証し、一定の効果を示した¹²⁾。具体的には、位置推定に広く適用されているパーティクルフィルタをベースに、センサごとに算出される位置情報を離散確率分布で表現、各センサから得る確率分布間の類似性評価を行ない、それを基に確率分布を多数決的に選択・統合する手法を提案した。先行研究の実機検証において、多数決的なセンサ統合の枠組みはおおむね有効に機能したが、選択法に起因する問題により、環境によっては有用なセンサの選択を誤る事例が見られた。本論文では、先行研究でセンサ選択を誤る要因を明確にし、位置推定に適した確率分布間の類似性評価法、および、位置情報の選択法を提案する。シミュレーションと実機検証により、提案統合システムにより有用なセンサが正しく選択され、位置推定のロバスト性が向上することを示す。

2. 先行研究

先行研究の相対評価に基づく多数決的なセンサ統合システムを Fig. 1 に示す。Fig. 1 では、各センサから得る位置情報をパーティクルを用いた確率分布で表現 (Block A)、各確率分布の相対評価により分布の類似するセンサを多数決的に選択 (Block B)、選択されたセンサから得る分布を積により統合する (Block C)。以下詳細を記す。

2.1 パーティクルによる確率分布表現と統合

Block A では、センサ m ($m = 1, 2, \dots, M$) から得る位置情報を、パーティクル s_n ($n = 1, 2, \dots, N$) を用いて、離散確率分布 $p_m(s_n)$ の形式で表現する。なお、 s_n は、ロボット位置と同次元の位置候補点である。表現能力の高いパーティクルにより、確率的な位置推定法において研究された既存の観測モデル^{1), 3), 4)}を活用できる。すなわち、センサの種類・特性に応じた既存の観測モデルを併用することで、位置推定のロバスト化を試みる。

センサから得た $p_m(s_n)$ を次式で統合する (Block C)。

$$p(s_n) = \alpha \prod_{m=1}^M [p_m(s_n)]^{b_m} \quad (1)$$

ここで、 α は正規化係数である。また、 b_m は 0 か 1 をとる選択係数であり、Block B のセレクトで決定される値である。 $b_m = 0$ のとき、 $[p_m(s_n)]^{b_m} = 1$ となるため $p_m(s_n)$ は統合に影響せず、 $b_m = 1$ となる $p_m(s_n)$ のみ積算統合される。積算統合は同時確率の算出に相当し、位置候補の絞り込みに適している。統合した $p(s_n)$ の加重平均 ((2)式)²²⁾により推定位置 $\hat{x}$ を算出する。

$$\hat{x} = \sum_{n=1}^N s_n p(s_n) \quad (2)$$

ここで、観測したセンサ情報に大きな雑音 (観測ノイズや環境変動などに起因する雑音) が含まれると、Fig. 1 の $p_1(s_n)$ のように、真の位置での確率値が著しく低い確率分布 (バイアス分布) を得る場合がしばしばある。真値付近の確率値が低いバイアス分布を積算統合すると、大きな位置推定誤差を招く。Block B 内でバイアス分布を検出・排除し、残りの分布を積算統合 ((1)式) することで、位置の絞り込みによる高精度化と位置推定のロバスト化を図る。

2.2 相対評価による選択法

Block B では、センサ m に対する b_m を、ほかの分布に対する $p_m(s_n)$ の特異性から求める。特性が異なる複数センサ m からのおの $p_m(s_n)$ を求める場合、センサごとに雑音の影響が異なると仮定する。すなわち、雑音の影響が少ないセンサ群は、 $p_m(s_n)$ が類似し、雑音の影響が大きいバイアス分布は相対的に特異な分布になる。その仮定の下では、同時に類似したバイアス分布が生じることは稀となることから、 $p_m(s_n)$ の相対的な特異性からバイアス分布を検出する。

処理の概略を Fig. 2 に示す。全 M 個の $p_m(s_n)$ から基準分布 $q(s_n)$ を求め、 $p_m(s_n)$ と $q(s_n)$ の相違度 d_m が高い分布をバイアス分布とみなして $b_m = 0$ 、それ以外の分布を $b_m = 1$

Fig. 2 Previous selector (Block B)

として選択する．以下，相違度 d_m と選択係数 b_m の算出法を説明する．

2.2.1 確率分布間の類似性評価

$p_m(s_n)$ は確率分布であるから，一般的な確率分布間の類似性評価指標である KL 情報量を導入する．KL 情報量の定義式に従い，全 M 個の相違度 d_m を次式により求める．

$$d_m = \sum_{n=1}^N p_m(s_n) \log_2 \frac{p_m(s_n)}{q(s_n)} \quad (3)$$

ここで， $q(s_n)$ をすべての m で共通にすることで，距離定義を満たさない KL 情報量から各センサの相対的な相違度を評価する．なお，KL 情報量は，全 n において $p_m(s_n) = q(s_n)$ が成り立つ場合に $d_m = 0$ となり， $p_m(s_n)$ と $q(s_n)$ の類似性が低くなるにつれて d_m は高くなる．

比較基準の $q(s_n)$ は，全 M 個の $p_m(s_n)$ の平均分布とする (4) 式)．

$$q(s_n) = \frac{1}{M} \sum_{m=1}^M p_m(s_n) \quad (4)$$

個々の $p_m(s_n)$ のピーク形状を均等に反映する平均分布は，相対評価の基準分布に適すると考えられる．

2.2.2 センサ選択

d_m は $q(s_n)$ からの相対的な相違度であり，観測した $p_m(s_n)$ に依存する値である．そのため，一定の閾値は設定できない．そこで，(3) 式で求めた全 M 個の d_m から動的な閾値 d_{th} を設定，相対的に外れた d_m を検出する． d_{th} は，二乗平均平方根 (5) 式) によって算出する．

$$d_{th} = \sqrt{\frac{1}{M} \sum_{m=1}^M d_m^2} \quad (5)$$

$d_m > d_{th}$ を満たす $p_m(s_n)$ は，相対的に特異なバイアス分布となったと考え， $b_m = 0$ とする． $d_m < d_{th}$ となるセンサ m を $b_m = 1$ として選択し， $p_m(s_n)$ を統合に用いる．

3. 先行研究のシミュレーション検証

先行研究では，多数決的な統合法の枠組みの有効性は確認したものの，環境によっては有用なセンサの選択を誤る事例があった．本章では，シミュレーションにより先行研究を再度検証し，問題点を明らかにする．

Table 1 Simulation parameter

	K	ϕ_k	$\mu_{x,k}, \mu_{y,k}$	$\sigma_{x,k}, \sigma_{y,k}$
True	1-5	$\begin{cases} \sum_k \phi_k = 1 \\ \phi_1 > \phi_k \quad (k \neq 1) \end{cases}$	0-1	0.01-0.3
Bias	1	1	$(b_x, 0)^T$	0.01-0.3

3.1 シミュレーション条件

二次元空間 ($x = -1 \sim 1$, $y = -1 \sim 1$) に，1000 個のパーティクル $s_n = (x_n, y_n)^T$ を生成 ($N = 1000$) し，真値 $(x, y)^T = (0, 0)^T$ を推定するシミュレーションを行なった．センサ数は多数決が機能する最低限の 3 とした ($M = 3$)．

真値を含む分布 (真値における確率値が高い分布) の観測モデルを多変量 Gaussian Mixture Model ((6) 式) で模擬した．

$$p_m(s_n) = \phi_1 f(s_n; (0, 0)^T, \Sigma_1) + \sum_{k=2}^K \phi_k f(s_n; \mu_k, \Sigma_k) \quad (6)$$

$$\mu_k = \begin{pmatrix} \mu_{x,k} \\ \mu_{y,k} \end{pmatrix} \quad (7)$$

$$\Sigma_k = \begin{pmatrix} \sigma_{x,k}^2 & 0 \\ 0 & \sigma_{y,k}^2 \end{pmatrix} \quad (8)$$

ここで， K は混合数， $f(s_n; \mu_k, \Sigma_k)$ は平均 μ_k ，分散 Σ_k をもつ多変量正規分布の確率密度関数， ϕ_k は k 番目の正規分布の混合比であり， $\sum_{k=1}^K \phi_k = 1$ を満たす．(6) 式の右辺第一項は真値 $(0, 0)^T$ を平均とする正規分布であり， $\phi_1 > \phi_k$ ($k \neq 1$) とすることで，真値の確率値が最も高い分布の観測モデルとした．また，バイアス分布の観測モデルを次式で定義する．

$$p_m(s_n) = f(s_n; (b_x, 0)^T, \Sigma_1) \quad (9)$$

ここで， b_x はバイアス量である．単峰性の正規分布モデルとすることで，積算統合において b_x に応じて誤差を増加させるモデルとなる．センサ $m = 1, 2$ の $p_m(s_n)$ を (6) 式で，バイアス分布となるセンサ $m = 3$ の $p_3(s_n)$ を (9) 式で算出した．実空間での多様な確率分布を再現するために，Table 1 のパラメータをランダム変化させ，多様な確率分布を生成する． $b_x = 0.1, 0.2, \dots, 0.9$ と 0.1 刻みで変化，各 b_x ごとに 1000 回試行を行ない，選択性を検証する．

3.2 シミュレーション結果

真値を含む分布，および，バイアス分布の選択率を Fig. 3 に示す．横軸が b_x ，縦軸が選択率を表わし，丸が $m = 1, 2$ (真値を含む分布) の選択率，三角が $m = 3$ (バイアス分布) の選択率を示す． b_x の増加に伴いバイアス分布が正しく検出できるようになり，選択率が低下した．すべての b_x でバイアス分布の選択率が真値を含む分布より低い一方で，3 割程度のバイアス分布が選択されてしまった．バイアス分布が選択された事例として， $b_x = 0.7$ の $p_m(s_n)$ を Fig. 4 に示す．横軸，縦軸は，おのおの x, y 座標を表わし，各点が s_n ，色の

Fig. 3 Use rate of probability distributions

Fig. 5 Estimation error

Fig. 4 Probability distributions when $b_x = 0.7$ Table 2 KL-Divergences (d_m) of Fig. 4

	KL-Div	Use or not
$p_1(s_n)$	11.6	
$p_2(s_n)$	1.70	Use
$p_3(s_n)$	4.17	Use
d_{th}	7.18	

濃さが確率値に対応する。また、各 $p_m(s_n)$ に対する d_m と d_{th} を Table 2 に示す。Table 2 より、 $p_2(s_n)$ に加えてバイアス分布となる $p_3(s_n)$ の d_m が d_{th} を下回り、結果としてバイアス分布も選択されてしまった。

つぎに、バイアス分布の統合が位置推定に与える影響を確認するために、 b_x と推定誤差の関係を Fig. 5 に示す。横軸が b_x 、縦軸が推定誤差を表わす。全分布を積算統合する場合、 b_x の増加に伴い推定誤差が増加するが、先行研究の統合システムにより、大きな b_x をもつバイアス分布を統合しないことで推定誤差の増加が抑制された。一方、 $b_x \leq 0.3$ では、バイアス分布を適切に検出できず、全分布を積算統合した場合に対して推定誤差が増加した。

3.3 先行研究の問題点

先行研究における統合システムでは、2.2 節で述べた選択法の類似性評価指標である KL 情報量に問題があり、バイア

Fig. 6 Cases of KL-Divergences are high

ス分布のみを適切に検出・排除できない場合があった。

KL 情報量の問題点は、KL 情報量が確率分布間の分布形状の差 (Fig. 6 (a)) と分布位置の差 (Fig. 6 (b)) に基づいて相違度を算出する点である。先行研究において、比較基準である平均分布 $q(s_n)$ はすべての $p_m(s_n)$ を平滑化したなだらかな分布である。そのため、なだらかな分布形状となる $p_m(s_n)$ の d_m が低くなりやすい。Fig. 4 を見ると、 $q(s_n)$ に形状が類似した $p_2(s_n), p_3(s_n)$ の d_2, d_3 が低くなり選択されてしまった。 $p_3(s_n)$ のようにほかの分布に対して分布の位置が異なるバイアス分布であっても、 $q(s_n)$ と形状が類似しているために d_3 が低く選択されてしまい、推定精度が低下する問題が先行研究にあった。

以上より、確率分布間の分布位置の差に基づく類似性評価指標と平均分布を用いない選択法が求められる。

4. 提案する選択法

先行研究における問題点に対して、KL 情報量に代わる新たな類似性評価指標と、平均分布を用いない新たな選択法について述べる。

4.1 類似性評価指標

類似性評価指標が、位置推定におけるバイアス分布検出に不適であった。そこで、確率分布を s_n によって離散近似している点に着目し、確率値の相関性により類似性を評価する手法を提案する。2つの確率分布の相関性を次式に示すピアソンの相関係数²³⁾により評価する。

$$\rho_{m,l} = \frac{\text{Cov}[p_m(s_n), p_l(s_n)]}{\sigma_m \sigma_l} \quad (10)$$

ここで、 $\text{Cov}[p_m(s_n), p_l(s_n)]$ は、 $p_m(s_n), p_l(s_n)$ 間の共分散、おののお σ_m, σ_l は、 $p_m(s_n), p_l(s_n)$ の標準偏差である。ピアソンの相関係数は、2つのデータ系列が連動して変化する

Fig. 7 Similar probability distributions

Fig. 8 Non similar probability distributions

傾向の類似性を表わす指標である。本手法では、2つの確率分布の確率値が連動して変化する度合いの類似性を評価する。

例として、Fig. 7(a)に示すように、確率分布対の位置が類似する場合について考える。このとき、 s_i において $p_m(s_i), p_l(s_i)$ がともに高く、 s_j において $p_m(s_j), p_l(s_j)$ がともに低い。横軸 $p_m(s_n)$ 、縦軸 $p_l(s_n)$ としたFig. 7(b)の散布図で見ると、 $p_m(s_n)$ の増加に伴って $p_l(s_n)$ も増加する。つまり、 $p_m(s_n)$ と $p_l(s_n)$ の間には正の相関があり、 $\rho_{m,l}$ の値は1に近くなる。一方、Fig. 8(a)に示すように、確率分布対の位置が類似しない場合、 s_i において $p_m(s_i)$ が大きい $p_l(s_i)$ が小さく、逆に、 s_j において $p_m(s_j)$ が小さい $p_l(s_j)$ が大きい。横軸 $p_m(s_n)$ 、縦軸 $p_l(s_n)$ としたFig. 8(b)の散布図で見ると、 $p_m(s_n)$ の増減に対して $p_l(s_n)$ は類似しない。負または無相関となり、 $\rho_{m,l}$ の値は-1に近くなる。以上のように、 $\rho_{m,l}$ によって、 $p_m(s_n), p_l(s_n)$ 間の位置のずれに基づいた評価が可能となる。 $\rho_{m,l}$ に閾値 ρ_{th} を設けることで、相関値に基づいた確率分布の類似性評価ができる。

4.2 選択法

先行研究における平均分布に起因した問題を避けるために、確率分布間の類似性を1対1で評価、類似するセンサ数から統合する分布を選択する。提案する選択法をFig. 9に示す。センサ選択の基本原則として、多数決に基づく。各 $p_m(s_n)$ 間の類似性を相関係数により評価、 $p_m(s_n)$ と類似するセンサ数 L_m （自身を含む）を求める。全センサ数の過半数以上と類似（ $L_m \geq M/2$ ）する $p_m(s_n)$ を選択（ $b_m = 1$ ）し、(1)式により統合する。

$p_m(s_n)$ にバイアス分布が含まれていない場合、すべての m において $L_m \geq M/2$ と評価され、すべての $p_m(s_n)$ を積算統合することができる。また、すべての m において $L_m < M/2$ と評価された場合、 $p_m(s_n)$ はおのおの異なる位置に存在し

Fig. 9 Proposed selector (Block B)

Fig. 10 Use rate of probability distributions of the proposed system

Table 3 Pearson correlation coefficient ($\rho_{m,l}$) of Fig. 4

	$p_1(s_n)$	$p_2(s_n)$	$p_3(s_n)$	L	Use or not
$p_1(s_n)$	1	0.762	-0.0428	2	Use
$p_2(s_n)$	0.762	1	-0.0693	2	Use
$p_3(s_n)$	-0.0428	-0.0693	1	1	

ていると考え、尤もらしい確率分布は全確率分布の積算統合を求める。

本選択法により、平均分布を必要とせず、バイアス分布のみを適切に検出できる。

4.3 シミュレーション検証

3章におけるシミュレーションと同様の条件により、提案統合システムの選択性を検証した。位置推定で利用されるセンサは、種類ごとに特性が大きく異なるため、算出される確率分布の相関性は大きくない。一般的には、 ρ が0.2以上で正の相関とするが、提案統合システムでは、弱い正の相関をもつ確率分布対でも選択できるように $\rho_{th} = 0.1$ とした。

結果をFig. 10に示す。提案統合システムでは、 b_x が増えるに従ってバイアス分布の選択率が先行研究に比べ顕著に下がっている。

$b_x = 0.7$ のときに得た確率分布 (Fig. 4) に対して、提案統合システムで算出された $\rho_{m,l}$ をTable 3に、確率分布間の散布図をFig. 11に示す。Table 3とFig. 11より、真値を含む分布である $p_1(s_n), p_2(s_n)$ の間で正の相関（ $\rho_{1,2} \geq \rho_{th}$ ）となり、ほかの分布間では無相関（ $\rho_{1,3}, \rho_{2,3} < \rho_{th}$ ）となっている。提案統合システムでは、 $p_1(s_n), p_2(s_n)$ の分布を選択し、適切なセンサ選択を行なうことができた。結果、Fig. 12に示すように、提案統合システムでは、バイアス分布である $p_3(s_n)$ の適切な排除により推定誤差が減少している。これらより、相関係数の有効性、および、先行研究における統合システムに対する提案統合システムの原理的有効性を確認した。

Fig. 11 Scatter plots of Fig. 4

Fig. 12 Estimation error of the proposed system

5. 実機検証

提案統合システムの有効性を実機を用いた位置推定実験により確認した。

5.1 実機検証条件

名古屋大学東山キャンパス内と愛知工業大学八草キャンパス内において位置推定実験を行なった。レーザスキャナ (北陽 UTM-30LX), 全方位カメラ (ヴィストン VS-C450U-200-TK)・GPS (ヘミスフィア A101 スマートアンテナ) を搭載した Fig. 13 のロボット (ドンプロボット TETRA-DS IV) を用いた ($M = 3$)。各センサの確率分布モデルとして, GPS は正規分布モデル¹⁾, 全方位カメラは Bag of Features (BoF)³⁾ による類似画像検索に基づく観測モデル, レーザスキャナは花井らの手法⁴⁾ を参考に点群マッチングに基づく観測モデルを用いた。 ρ_{th} は, 4.3 節と同様に 0.1 とした。

実験を行なった環境を Fig. 14 に示す。ビルが密集しており GPS がマルチパスエラーを受けやすい歩道 (Fig. 14 (a)), 自動車の出入りが多く画像特徴が変化しやすい駐車場 (Fig. 14 (b)), 周辺形状特徴が単調でありレーザスキャナによるマップマッチングが困難な広場 (Fig. 14 (c)) で実験を行なった。

Fig. 14 における地図上のひし形の位置を中心とした 15 m

Fig. 13 Robot

(a) Sidewalk

(b) Parking

(c) Square

Fig. 14 Experimental environment

格子内に 1000 個の s_n をランダムで生成 ($N = 1000$), センサごとに $p_m(s_n)$ を算出, 先行研究または提案統合システムにより $p(s_n)$ を生成, $p_m(s_n)$ の加重平均を推定位置 $\hat{x}$ とし, 推定位置と真の位置間のユークリッド誤差を算出した。

位置推定では, 一般的に時間遷移を組み込むが, 本検証では統合による位置推定への影響を考察することを目的とし, 時間的に独立に位置推定 (位置ごとに独立に $p_m(s_n)$ を算出) を行なった。Fig. 14 (a)(b)(c) 内において, それぞれ 20, 39, 21 箇所で位置推定を行なった。なお, バイアス分布発生頻度や仮定可否検証のために, 真値を中心とした半径 2 m の円内にあるパーティクルの確率値の平均が $1/N$ 以下となる分布をバイアス分布と判定した。バイアス分布の発生頻度や, 仮定の可否, 提案統合システム, 先行研究による選択性を検証

Table 4 Experimental result

Environment (Bias/Total)	Fulfill precondition	Eliminate bias	
		Previous	Proposed
Sidewalk (10/20)	7 / 10	5 / 7	7 / 7
Parking (3/39)	3 / 3	1 / 3	3 / 3
Square (8/21)	8 / 8	7 / 8	8 / 8
Total (21/80)	18 / 21	13 / 18	18 / 18

Fig. 15 Probability distributions

した。

5.2 実機検証結果

Fig. 14 の計 80 箇所で行った計測の際の、バイアス分布発生箇所数や、仮定の可否、選択されたセンサを Table 4 に示す。計 21/80 箇所で行った計測の際に、バイアス分布が発生した。また、18/21 箇所で行った計測の際に、類似したバイアス分布が生じないという仮定を満たしていることを確認した。仮定を満たした箇所では、先行研究では、バイアス分布を適切に排除できた箇所は 13/18 箇所であった。しかし、残りの 5 箇所では、有用でないセンサから得るバイアス分布を選択し統合してしまった。それに対して、提案統合システムでは 18/18 箇所と、すべての箇所においてバイアス分布を適切に排除でき、選択性を改善できた。先行研究に比べ選択性が改善された 5 箇所では、平均 1.5m の推定誤差減少が確認された。先行研究より、提案法では、有用なセンサを適切に選択できる箇所が増えたことから、提案統合システムのロバスト性が向上したことを確認した。

Fig. 14(a) 内で得た $p_m(s_n)$ の一例を Fig. 15 に示す。Fig. 15 は、レーザスキャナで作成した占有格子地図上に確率分布を表現した図である。白と黒の領域がそれぞれレーザの通過領域と非通過領域である。点群が s_n の位置を表わし、色の濃さで確率値の大きさを表わす。ひし形の位置が真の位置である。また、Fig. 15(d)(e) の星形の位置は、各統合手法で得た推定位置を表わす。Fig. 15 より、GPS から得る確率分布がバイアス分布となった。先行研究では、なだらかな分布形状である GPS とカメラが選択された (Table 5) が、提案統合システムでは、分布位置が類似したカメラとレーザスキャナを適切に選択できた (Table 6)。結果として、この位置において、先行研究における統合システムにおける推定誤

Table 5 KL-Divergences d_m of Fig. 15

	KL-Div	Use or not
GPS	0.729	Use
Camera	0.717	Use
Laser	0.923	
d_{th}	0.795	

Table 6 Pearson correlation coefficient $\rho_{m,l}$ of Fig. 15

	GPS	Camera	Laser	L	Use or not
GPS	1	-0.132	0.0912	1	
Camera	-0.132	1	0.235	2	Use
Laser	0.0912	0.235	1	2	Use

差は 4.0m であったのに対して、提案統合システムにおける推定誤差は 2.2m であり、1.8m の推定誤差減少を確認した。

以上より、先行研究における統合システムに対する提案統合システムの有効性を確認した。

6. ま と め

自律移動ロボットの自己位置推定におけるロバスト性向上のために、特性が異なる複数のセンサから得る確率分布の統合に着目した。先行研究では、確率分布の類似性に基づいてバイアス分布を検出・排除し残りを統合するシステムが提案されたが、選択法に問題があった。本論文では、新たな選択システムとして確率分布の 1 対比較による選択、および、新たな類似性評価指標として相関に基づく手法を提案した。シミュレーションおよび実機検証において、先行研究における統合システムに対する提案統合システムの有効性を確認した。今後、パーティクルフィルタによる時系列遷移を含めた位置推定実験にて、提案統合システムの有効性を確認する。

参 考 文 献

- 山崎, 竹内, 大野, 田所: 三次元地形情報および GPS を用いたパーティクルフィルタによるマルチパスを考慮した自己位置推定, 日本ロボット学会誌, **29-8**, 702/709 (2011)
- J. Biswas and M. Veloso: Depth Camera Based Indoor Mobile Robot Localization and Navigation, IEEE Int. Conf. Robot. Automat., 1697/1702 (2012)
- 飯村, 山本: 搭乗型移動支援ロボット『ROPITS®』の開発—類似画像検索による自己位置ロストからの回復—, 第 27 回ロボティクス・メカトロニクス講演会講演概要集, 1P2-G05 (2015)
- 花井稔典: Plug-in Hybrid Vehicle の自動充電を目指した自律移動ロボットの動作計画に関する研究, 修士学位論文, 愛知工業大学 (2013)
- J. Kim and W. Chung: Localization of a Mobile Robot Using a Laser Range Finder in a Glass-Walled Environment, IEEE Trans. Ind. Electron., **63-6**, 3616/3627 (2016)
- A. Hornung, K.M. Wurm and M. Bennewitz: Humanoid Robot Localization in Complex Indoor Environments, IEEE/RSJ Int. Conf. Intell. Robot. Syst. (IROS), 1690/1695 (2010)
- 山田, 大矢: 生活環境における移動ロボットの自己位置推定のためのレーザスキャナの統計的計測モデル, 計測自動制御学会論文集, **52-12**, 661/670 (2016)
- D. Maier and A. Kleiner: Improved GPS Sensor Model for Mobile Robots in Urban Terrain, IEEE Int. Conf. Robot.

Automat., 4385/4390 (2010)

- 9) M. Cummins and P. Newman: FAB-MAP Probabilistic localization and mapping in the space of appearance, The Int. J. Robot. Res. **27**-6, 647/665 (2008)
- 10) K. Wang, Y. Liu and L. Li: A Simple and Parallel Algorithm for Real-Time Robot Localization by Fusing Monocular Vision and Odometry/AHRS Sensors, IEEE/ASME Transactions on Mechatronics, **19**-4, 1447/1457 (2014)
- 11) T.N. Hossein, S. Mita, L. Han and Q. Do: Multi-Sensor Data Fusion for Autonomous Vehicle Navigation and Localization through Precise Map, Int. J. Autom. Eng., **2**-1, 19/25 (2012)
- 12) 栗山, 舟洞, 道木, 道木: パーティクルフィルタを用いた自己位置推定のロバスト性向上を目指した確率分布の類似性に基づく動的なセンサ選択, 計測自動制御学会論文集, **53**-2, 169/177 (2017)
- 13) F. Caron, M. Davy, E. Duflos and P. Vanheeghe: Particle filtering for multisensor data fusion with switching observation models: Application to land vehicle positioning, IEEE Trans. Signal Process., **55**-6, 2703/2719 (2007)
- 14) A. Giremus, J.Y. Tournet and V. Calmettes: A Particle Filtering Approach for Joint Detection/Estimation of Multipath Effects on GPS Measurements, IEEE Trans. Signal Process., **55**-4, 1275/1285 (2007)
- 15) L. Wei, C. Cappelle and Y. Ruichek: Camera/Laser/GPS Fusion Method for Vehicle Positioning Under Extended NIS-Based Sensor Validation, IEEE Trans. Instrumentat. Meas., **62**-11, 3110/3122 (2013)
- 16) 小河原, 羽多野, 藤井, 伊藤, 渡辺: GPS 測位情報とセンサ情報に基づく位置推定システムに関する研究, 情報処理学会論文誌, **56**-1, 2/12 (2015)
- 17) 興梠, 蔵田: 組み込み型 GPS・自蔵式センサシステムによる屋内外歩行者ナビ, 電子情報通信学会技術報告, **106**-73, 75/80 (2006)
- 18) R. Mur-Artal and J.M.M. Montiel: ORB-SLAM: A Versatile and Accurate Monocular SLAM System, IEEE Trans. Robotics, **31**-5, 1147/1163 (2015)
- 19) 由井, 小林, 野沢, 平谷, 内村: ディープラーニングによる探索および信号認識機能を有する自律移動ロボットの開発, つくばチャレンジ 2016 参加レポート, 12/15 (2016)
- 20) H. Durrant-Whyte: *Multi Sensor Data Fusion*, Australian Centre for Field Robotics (2001)
- 21) J.A. Catellanos, J. Neira and D. Tardos: Multisensor Fusion for Simultaneous Localization and Map Building, IEEE Trans. Robot. Automat., **17**-6, 908/914 (2001)
- 22) S. Thrun, W. Burgard and D. Fox: *Probabilistic Robotics*, MIT Press (2005)
- 23) R.A. Fisher: *Statistical Methods for Research Workers*, 13th edition, Hafner (1958)

舟 洞 佑 記 (正会員)

2012 年名古屋大学大学院工学研究科博士課程後期課程電子情報システム専攻満期退学。同年理化学研究所基幹研究所特別研究員, 2013 年名古屋大学大学院工学研究科電子情報システム専攻助教, 現在に至る。博士 (工学)。主として, ロボティクス, 知能制御, ソフトコンピューティングに関する研究に従事。IEEE, 日本機械学会, 電子情報通信学会, 電気学会, IEEE 会員。

道 木 慎 二 (正会員)

1995 年名古屋大学大学院工学研究科博士課程後期課程電子機械工学専攻修了。同年同大学助手, 2000 年三重大学助教授, 2004 年名古屋大学助教授, 2007 年同大学准教授, 2012 年同大学教授, 現在に至る。博士 (工学)。主として, 制御理論にもとづく電動機制御, および制御のためのパターン情報処理・信号処理・モデリングとその応用に関する研究に従事。電子情報通信学会, IEEE 会員。IEEE IECON'92 best paper award, 平成 14 年度ファナック FA ロボット財団論文賞, 平成 16, 27 年電気学会電気学術振興賞 (論文賞) を受賞。

道 木 加 絵 (正会員)

2002 年名古屋大学大学院工学研究科博士課程後期電機電子工学専攻満了, 同年修了。同年愛知工業大学工学部電気工学科助手。講師を経て, 2007 年愛知工業大学工学部機械学科准教授, 2012 年愛知工業大学工学部電気学科准教授, 現在に至る。博士 (工学)。ロボティクス, 知能制御システム, 知的情報処理に関する研究に従事。IEEE, 日本ロボット学会, 電気学会会員。

[著 者 紹 介]

大 橋 臨 (学生会員)

2018 年名古屋大学大学院工学研究科博士課程前期電子情報システム専攻修了。同年名古屋大学大学院工学研究科博士課程後期課程情報・通信工学専攻, 現在に至る。主として移動ロボットの自己位置推定に関する研究に従事。