特異環境を考慮した LRF マップマッチングとオドメトリの MHE 融合に基づく移動ロボットの自己位置推定

栄 田 国 志*・木 村 一 輝*
野 中 謙一郎**・関 口 和 真**

Mobile Robot Localization Integrating LRF Map-matching and Odometry
Based on Moving Horizon Estimation Considering Singular Environments

Kuniyuki SAKAETA*, Kazuki KIMURA*,
Kenichiro NONAKA** and Kazuma SEKIGUCHI**

In this paper, we propose a localization method integrating laser range finder (LRF) measurement and odometry by moving horizon estimation (MHE). The position and the attitude angle of a robot are estimated by solving an optimization problem using multiple sampling data while shifting the evaluation interval at each sampling. The relative importance of the estimations of LRF and odometry are balanced by adapting to the number of LRF measurements. With the proposed method, accurate localization can be realized even in singular environments where the self-pose cannot be localized using only LRF measurements. The accuracy of the proposed method is verified through comparisons with conventional methods on numerical simulations. In addition, we verify the robustness and feasibility of the proposed method for singular environments through numerical simulations and experiments.

Key Words: localization, moving horizon estimation, laser range finder, map-matching, odometry

1. 緒 言

1.1 背景

近年、作業効率や安全性の向上を目的に自律移動ロボットに関する研究が多く行なわれている。ロボットが移動する際には動作環境内における自己の位置、姿勢をセンサ計測値から正確に推定する必要がある^{1), 2)}。自己位置推定にはエンコーダや加速度センサ、ジャイロセンサなどの内界センサと、Laser Range Finder (以下 LRF とする) やステレオカメラ、超音波センサなどの外界センサを用いる手法がある。内界センサを用いた自己位置推定手法であるオドメトリ^{3), 4)}では、ロボットのダイナミクスから得られる移動量を積算することで自己位置を推定する。しかしシステムノイズや、タイヤのスリップによる誤差の累積が問題となる。一方で外界センサを用いた手法では、ロボットの周囲の特徴を計測し、その方位や距

離、座標から自己位置を推定する。よって誤差の累積は生じないが、観測ノイズや外れ値が問題となる。

LRF は角度分解能や距離計測精度が高く、多くの手法に用いられている。LRF 計測値を用いた自己位置推定手法の例として、拡張カルマンフィルタ (以下 EKF とする) やパーティクルフィルタ (以下 PF とする) を用いたモデルベースのフィルタリング手法と、最適化計算によるマッチング手法が挙げられる。EKF などでは、LRF 計測データから検出した線分やエッジなどを観測値に用いて推定する^{5)~7)}。一方で最適化計算によるマッチング手法では、既知もしくは過去の観測で得られた周囲物体の形状や位置と、LRF 計測データそれぞれの対応付けを行ない、最適化計算によりその一致誤差を最小化するロボットの位置、姿勢を推定する^{8)~10)}。よって多くの LRF 計測データを直接用いた推定を行なえるため、フィルタリング手法に比べその推定精度やノイズに対するロバスト性が高くなることが期待される¹¹⁾。しかしマッチング手法では、特徴の少ない平行な壁や円形の壁に囲まれた環境において、LRF 計測値のみではロボットの位置と姿勢を一意に決定できないため自己位置推定に失敗する。こういった特異環境における自己位置推定問題が議論されており^{12), 13)}、特に文献 13) では、平行な壁や円形の壁に囲まれた環境においてフィッシャー情報行列が非正則になることを示している。た

* 東京都市大学大学院工学研究科 東京都世田谷区玉堤 1-28-1

** 東京都市大学工学部 東京都世田谷区玉堤 1-28-1

* Graduate School of Engineering, Tokyo City University,
1-28-1 Tamazutsumi, Setagaya-ku, Tokyo

** Faculty of Engineering, Tokyo City University, 1-28-1
Tamazutsumi, Setagaya-ku, Tokyo

(Received November 14, 2016)

(Revised March 31, 2017)

例えば建物内の廊下では、LRF の測距範囲の制限や障害物に遮蔽されることで、1 つもしくは 1 組の平行な壁しか観測できない特異環境となる可能性がある。またカメラ画像を用いた推定手法では、複数のカメラや時刻で撮影した画像中の特徴点から最適化計算によりカメラの位置や姿勢を推定するバンドル調整が用いられている¹⁴⁾。しかし LRF を用いた手法と同様に、得られる特徴が少ない環境では推定の失敗が考えられる。よって特異環境でのロボットの動作も考慮した自己位置推定手法が必要とされる。モデルベース推定手法である EKF では、特異環境においてもロボットの動作モデルによる予測で特異方向の情報を補い推定を達成できる。しかし繰り返し計算を用いない EKF と、高い推定精度が期待できるマッチング手法を直接融合することは困難である。

また状態推定手法として、最適化問題を解くことで状態を推定する Moving Horizon Estimation (以下 MHE とする) が近年注目されている。MHE では、有限時間過去から現在時刻までの予測観測誤差とロボットの動作モデル予測誤差を最適化計算により評価し、サンプリングごとに評価区間を移動しながらその終端値を現在時刻の推定値とする。文献 15) では、MHE と EKF の推定精度を比較し、MHE が優位であることを示している。ロボットの自己位置のみでなく周囲の環境地図を同時に推定する SLAM 問題では全時刻の予測観測誤差とロボットの動作モデル予測誤差を最適化計算により評価する Graph-SLAM が用いられている¹⁾。自己位置推定問題への MHE の適用は、この Graph-SLAM の評価区間を一定区間に区切り逐次移動し、自己位置のみを推定する問題となる。SLAM 問題では過去に観測した特徴と、その特徴を再び観測した際の推定値の矛盾を解消するために、長い評価区間の最適化問題を解く必要があり計算量が膨大になる。しかし既知環境での自己位置推定問題において、与えられた地図は真値であり推定する必要がない。よって MHE により短い区間の最適化問題を繰り返し解くことで十分な推定精度が得られると考えられる。MHE においても高い計算コストが問題とされているが、近年の計算機の発達や、最適化問題を高速に解くためのアルゴリズムの研究^{16), 17)}によって、リアルタイム制御への実装が可能になりつつある。自己位置推定問題への適用例として、文献 18) では 1 機のビーコンからの距離計測値を用いた水中ロボットの自己位置推定に MHE を適用している。1 機のビーコンからの距離計測値のみでは常にロボットの位置を決定できない問題となる。MHE では現在時刻だけでなく過去の距離計測値も推定に用いることで、その推定精度を向上している。

そこで本論文では、LRF 計測値を用いた最適化計算による自己位置推定とオドメトリを MHE によって融合した自己位置推定手法を提案する。提案手法では、MHE の評価関数で LRF 計測値を用いた位置推定誤差、オドメトリの推定誤差、初期値推定誤差の 3 つの項を評価して同時最適化を行なう。これにより、LRF 計測値から推定に十分な情報が得られる環境では LRF 計測データを直接用いた高精度な推定を達成す

る。さらに特異環境においても特異方向の情報を動作モデルによる予測で補うことで最適化計算の失敗を防ぎ、自己位置推定を達成する。また LRF 計測データから推定に用いる情報が多く得られない場合には、その観測ノイズの影響を受けやすい。提案手法では、LRF 計測データから得られる情報量の増減に応じて各評価項の信頼度合いが相対的に変化するため、周囲の環境に対応しながら推定できる。われわれの過去の研究では、障害物や LRF の走査範囲の制限によりある時刻で計測値が一部欠落する環境において、MHE により自己位置推定が達成できることを確認した¹⁹⁾。また建物内の廊下のような平行な 2 つの壁しか LRF で観測できない区間が存在する特異環境で、MHE では特異方向の情報を動作モデルで補いながら自己位置推定を達成することを示した²⁰⁾。そこで本論文では上記の廊下のような環境に LRF で円形の壁しか観測できない特異環境も加え、より一般性のある検証を行なう。そしてこれらが複合した環境において実機実験による検証を行ない、MHE を用いた自己位置推定手法が有効であることを示す。

1.2 本論文の構成

2 章では、オドメトリや LRF 計測データを用いたマップマッチングによる従来の自己位置推定手法を述べる。続く 3 章では、LRF 計測データを用いたマップマッチングでは自己位置推定に失敗する特異環境について述べる。そして 4 章では、提案手法である LRF 計測データを用いたマッチング手法とオドメトリの MHE 融合による自己位置推定手法を示し、特異環境における有効性を述べる。続く 5 章では、数値シミュレーションにより提案手法とマップマッチング、EKF、PF を用いた自己位置推定手法の推定精度の比較を行ない、提案手法が従来手法と同程度の自己位置推定精度を有することを示す。そして 6 章では、特異環境においても提案する自己位置推定手法は LRF 計測データを有効に用いた自己位置推定を達成できることを、数値シミュレーションにより示す。7 章では、実機実験により提案手法の自己位置推定精度および特異環境における有効性を示す。そして提案手法はリアルタイム推定が可能な計算量であることを示す。最後に 8 章で結論を述べる。

2. 従来の自己位置推定手法

2.1 オドメトリによる手法¹⁹⁾

時刻 k におけるロボットの状態をその位置と姿勢角 $\mathbf{x}_k = (x_k, y_k, \theta_k)^T$ 、入力ベクトルを $\mathbf{u}_k$ とし、対象のダイナミクスを (1) 式の離散系で表わす。

$$\mathbf{x}_{k+1} = \mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) + \mathbf{v}_k \quad (1)$$

右辺第二項のシステムノイズ $\mathbf{v}_k$ を除いた式を動作モデルとする。各サンプリングで得られる計測値を用いて動作モデルを積算することで、オドメトリによる自己位置推定を行なう。しかし実際はシステムノイズ $\mathbf{v}_k$ や未知外乱、離散化時に生じる近似誤差が加わり累積することで、推定精度が悪化する。

Fig. 1 Localization based on LRF data and map-matching

2.2 LRF 計測値を用いた最適化計算による手法¹⁹⁾

本論文ではおおまかなロボットの初期位置と環境地図の情報は既知で、周囲が壁に囲まれている環境を想定する。このとき、既知の地図情報と LRF によって得られるデータ間の一致誤差を最小にする、時刻 k におけるロボットの状態推定値 $(\hat{x}_k, \hat{y}_k, \hat{\theta}_k)^T$ を最適化計算によって求める。LRF による自己位置推定で想定する環境の例と各変数を Fig. 1 に示す。ここで $r_j (j = 1, 2, \dots, N)$ は LRF で得られる各方向 φ_j の計測データ、 $\hat{r}(\hat{x}_k, \hat{y}_k, \hat{\theta}_k, \varphi_j)$ は既知の地図情報から計算することができる理論距離である。LRF 計測データを用いてロボットの状態 $(\hat{x}_k, \hat{y}_k, \hat{\theta}_k)^T$ を推定する最適化問題を以下に示す。

Localization with LRF :

Minimize

$$J_m = \frac{1}{N_k} \sum_{j \in C_k} (\hat{r}(\hat{x}_k, \hat{y}_k, \hat{\theta}_k, \varphi_j) - r_j)^2 \quad (2)$$

with

$$N_k = n(C_k)$$

$$C_k = \{j \mid |\hat{r}(\hat{x}_k, \hat{y}_k, \hat{\theta}_k, \varphi_j) - r_j| < \epsilon\} \quad (3)$$

for $(\hat{x}_k, \hat{y}_k, \hat{\theta}_k)^T$.

ここで C_k は既知の壁を計測した自己位置推定に利用可能な LRF 計測データ、 N_k はその要素数を表す。地図情報に存在しない物体に対する計測データを含めて自己位置推定を行なうと推定精度が悪化する。そのため最適化計算を行なう前に、LRF 計測データと初期推定値から得られる理論距離の差を計算し、その差が閾値 ϵ より小さい計測データの集合を C_k とし最適化計算に用いる。

3. 特異環境における自己位置推定

本論文では、前章に示したマッチング手法では自己位置を一意に決定できない、特異環境における自己位置推定問題を扱う。例として Fig. 2(a) に示す、未知障害物による遮蔽や LRF 計測範囲外に壁が存在するといった理由で平行な一組の壁しか観測できない廊下などの環境や、Fig. 2(b) に示す円形の壁に囲まれた環境を考える。Fig. 2(a) に示す環境において、 X 軸に平行な壁に対する LRF 計測データからは、その壁

(a) Square environment with unknown obstacle.

(b) Circular environment.

Fig. 2 Failure environments of map-matching

に直交する方向の距離と壁の方位の情報が得られるため、ロボットの y 座標と姿勢角 θ を推定できる。しかしこの環境では x 座標の情報をもつ LRF 計測データが得られない。また Fig. 2(b) に示す環境においては、円の半径方向の位置は推定できるが、円周方向の情報を得られないため、位置 x, y と姿勢角 θ の組み合わせを一意に決定することができない。これらの特異環境においては、(2) 式の評価関数の最小化では解が一意に定まらない。本論文ではこの問題に対し、最適化計算を用いたモデルベース推定手法である MHE により、LRF 計測値を用いた最適化計算による手法とオドメトリを融合した自己位置推定を行なう。これにより LRF 計測データで得られない情報をオドメトリにより補間し、特異環境においても自己位置推定を達成する。

4. MHE に基づく自己位置推定

4.1 MHE に基づく自己位置推定の定式化

本論文では、オドメトリと LRF 計測値を用いた最適化計算による自己位置推定手法を、Moving Horizon Estimation (MHE) に基づいて融合した自己位置推定手法を提案する。MHE では、Fig. 3 のように各サンプリングで評価区間を移動しながら、評価区間内の計測値を用いた最適化問題を解くことによって状態を推定する。ここで T は現在時刻、 H は MHE の評価区間長である。提案手法である MHE による自己位置推定の最適化問題を以下に示す。

Localization with MHE :

Minimize

$$J = \sum_{k=T-H}^T \frac{1}{N} \sum_{j \in C_k} \frac{(\hat{r}(\hat{x}_k, \varphi_{k,j}) - r_{k,j})^2}{\sigma^2}$$

Fig. 3 Outline of moving horizon estimation

$$+ \sum_{k=T-H}^{T-1} \|\hat{\mathbf{x}}_{k+1} - \mathbf{f}(\hat{\mathbf{x}}_k, \mathbf{u}_k)\|_{\mathbf{Q}}^2 + \|\hat{\mathbf{x}}_{T-H} - \hat{\mathbf{x}}_{T-H}^-\|_{\mathbf{P}}^2 \quad (4)$$

for $\hat{\mathbf{x}}_k = (\hat{x}_k, \hat{y}_k, \hat{\theta}_k)^T \quad (k = T-H, \dots, T)$

右辺第1項は理論距離 $\hat{r}$ と LRF 計測距離 r の一致誤差, 第2項はオドメトリの推定誤差, 第3項は初期値推定誤差を評価する. σ^2 は LRF 計測値に加わる観測ノイズの分散, $\mathbf{Q}$ はシステムノイズ $\mathbf{v}_k$ の共分散である. また $\hat{\mathbf{x}}_{T-H}^-$ は一時刻前の MHE による推定値のうち時刻 $T-H$ に対応する値である. $\mathbf{P}$ は $\hat{\mathbf{x}}_{T-H}$ と初期推定値 $\hat{\mathbf{x}}_{T-H}^-$ の誤差に対する重みであり, チューニングパラメータである. 各項の分散の逆行列を MHE の重みに利用することで, 評価を正規化している. $\bar{N}$ は自己位置推定に用いられる LRF 計測データ数の典型値であり, 使用環境に応じてチューニングを必要とする. 右辺第2項の $\|\hat{\mathbf{x}}_{k+1} - \mathbf{f}(\hat{\mathbf{x}}_k, \mathbf{u}_k)\|_{\mathbf{Q}}^2$ は $(\hat{\mathbf{x}}_{k+1} - \mathbf{f}(\hat{\mathbf{x}}_k, \mathbf{u}_k))^T \mathbf{Q}^{-1} (\hat{\mathbf{x}}_{k+1} - \mathbf{f}(\hat{\mathbf{x}}_k, \mathbf{u}_k))$ を表わし, 右辺第3項に関しても同様の定義とする.

ここで, (4) 式の評価関数を用いた MHE による自己位置推定のアルゴリズムを以下に示す.

- (i) 初期推定値 $\hat{\mathbf{x}}_{T-H}^-$ を決定する.
- (ii) 現在時刻 $k = T$ における LRF 計測値, 入力値を取得し, これらを現在時刻のデータとして更新する.
- (iii) 最適化計算により, (4) 式の評価関数を最小にする評価区間にわたる状態 $\hat{\mathbf{x}}_k (k = T-H, \dots, T)$ を求める.
- (iv) 求めた推定値のうち, $\hat{\mathbf{x}}_T$ を現在時刻における推定値とする.
- (v) つぎのサンプリングでは評価区間を $k = T-H+1, \dots, T+1$ とし (i) へ.

また LRF 計測データから推定に用いる情報を多く得られない状態は, LRF の観測ノイズの影響を受けやすい. 本手法では自己位置推定に用いられる LRF 計測データ数の典型値 $\bar{N}$ で (4) 式の評価関数の第1項を除する. これにより LRF 計測データから得られる情報が少ない場合にはオドメトリ情報を重視した推定が行なわれる.

4.2 特異環境における MHE に基づく自己位置推定

2.2 節で述べた LRF 計測データを用いたマップマッチングによる自己位置推定では, 特異環境において (2) 式の評価関数の最小化では一意に解が定まらない. しかし, (4) 式を評

Fig. 4 Vehicle model

価関数とする MHE による自己位置推定では, (2) 式を評価区間だけ積算した (4) 式の第1項だけでなく, オドメトリに対応した第2項と, 初期値推定誤差を評価する第3項によって, 自己位置を得ることが可能になる. たとえば Fig. 2(a) に示す環境では, 推定のための LRF 計測データが十分に存在する y と θ に関しては LRF 計測値と動作モデルによる予測の両方から, 推定に必要な情報を得られる. また x 座標の推定に必要な情報は, MHE の評価関数である (4) 式でオドメトリの推定誤差と初期値推定誤差を評価することで得られる. このとき x 座標の推定値はオドメトリの累積誤差の影響を受けるが, y と θ に関しては LRF により得られる情報が反映されるため累積誤差の影響を抑制できる. Fig. 2(b) に示す環境においては, LRF 計測値が円の円周方向の位置と姿勢の情報をもたないため, その方向にオドメトリの推定誤差の影響を受ける. しかし半径方向の情報を得られるため, オドメトリのみの推定に比べその累積誤差の抑制が期待できる. またすべての LRF 計測値が取得できない場合においても, その区間中にオドメトリの累積誤差の影響を受けるが, 自己位置を推定できる. 以上より提案手法では, LRF 計測値を用いたマップマッチングとオドメトリのそれぞれの自己位置推定手法を1つの最適化問題に定式化することで, 特異環境においても自己位置推定を達成する.

5. 自己位置推定精度の検証

本章では数値シミュレーションにより, LRF 計測データが十分に得られる環境における提案手法の推定精度の検証を行なう.

5.1 オドメトリに用いる車両モデル

本論文では自律移動ロボットとして前輪操舵車両を用いる. 前輪操舵車両を左右輪の中心に車輪を置いた, Fig. 4 に示す二輪等価モデルとして扱い, 慣性座標系 $X-Y$ 上の車両の後輪間中心の位置および姿勢角を $(x, y, \theta)^T$, 車両速度を V , 操舵角を δ , ホイールベースを L とする. このとき車両ダイナミクスは以下の式で表わせる.

$$\frac{dx}{dt} = V \cos(\theta) \quad (5)$$

$$\frac{dy}{dt} = V \sin(\theta) \quad (6)$$

$$\frac{d\theta}{dt} = \frac{V}{L} \tan(\delta) \quad (7)$$

Fig. 5 Simulation environment 1

Fig. 6 Simulation environment 2

このダイナミクスを (1) 式のように離散化するために、時刻 k における車両の状態ベクトルを $\mathbf{x}_k = (x_k, y_k, \theta_k)^T$ とし、入力ベクトルを $\mathbf{u}_k = (V_k, \delta_k)^T$ とする。(1) 式の $\mathbf{f}(\mathbf{x}_k, \mathbf{u}_k)$ は、サンプリングタイム τ を用いて次式で表わせる。

$$\mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) = \mathbf{x}_k + \begin{pmatrix} V_k \cos(\theta_k) \\ V_k \sin(\theta_k) \\ \frac{V_k}{L} \tan(\delta_k) \end{pmatrix} \tau \quad (8)$$

5.2 MHE の最適化問題の解法

(8) 式で示す関数は非線形関数であるが、MHE による状態推定では、(4) 式を評価関数とする最小化問題をリアルタイムで解く必要がある。そこで本論文では計算量を削減するため、一つ前の MHE による推定値を用いて、(8) 式で表わされる非線形な車両ダイナミクスを拡張線形化する。推定値 $\hat{\mathbf{x}}_k^-(k = T - H, \dots, T - 1)$ まわりで 1 次のテーラー展開を行なうと (8) 式は以下ようになる。

$$\mathbf{f}(\mathbf{x}_k, \mathbf{u}_k) \approx \mathbf{f}(\hat{\mathbf{x}}_k^-, \mathbf{u}_k) + \left. \frac{\partial \mathbf{f}}{\partial \mathbf{x}_k} \right|_{\mathbf{x}_k = \hat{\mathbf{x}}_k^-} (\mathbf{x}_k - \hat{\mathbf{x}}_k^-) \quad (9)$$

ここで、車両の入力である $\mathbf{u}_k$ は、各時刻で保存した値を用いる。(4) 式の第 2 項の $\mathbf{f}(\hat{\mathbf{x}}_k, \mathbf{u}_k)$ を (9) 式を用いて近似する。また (4) 式の第 1 項に含まれる関数 $\hat{r}(\mathbf{x}_k, \varphi_j)$ も三角関数を含む非線形関数である。よって第 1 項については 1 つ前の MHE による推定値 $\hat{\mathbf{x}}_{k-1}^-(k = T - H, \dots, T - 1)$ と現在時刻の予測推定値 $\hat{\mathbf{x}}_T^-$ まわりで 2 次のテーラー展開を行なう。これにより自己位置推定のための最適化問題を二次計画問題として扱うことができる。本論文では (4) 式の評価関数を最小にする状態 $\hat{\mathbf{x}}_k(k = T - H, \dots, T)$ を SQP(Sequential Quadratic Programming) 法を用いて数値的に計算する。また最適化問題のソルバとして、Mattingley らの CVXGEN¹⁶⁾を用いる。このソルバは、二次計画問題を高速に解くコードを生成することができる。

5.3 シミュレーション条件

本章では Fig. 5 に示す周囲が直線の壁 W1, W2, W3, W4 に囲まれた環境と Fig. 6 に示す周囲が直線の壁 W1, W2, W4 と円形の壁 W3 に囲まれた環境で、自己位置推定に用い

Fig. 7 Laser range finder

Table 1 Specifications of UBG-04LX-F01

Manufacture	HOKUYO AUTOMATIC CO.,LTD.
Model	UBG-04LX-F01
Measuring distance	20 to 5600 mm
Measurement accuracy	0.06 to 1 m : ± 10 mm, 1 to 5.6 m : 1 % of distance
Scanning angle	240 deg
Angular resolution	0.36 deg(360 deg/1024)
Scanning time	28 ms/scan

る LRF 計測データが十分に得られる場合を想定した数値シミュレーションを行なう。これらの環境において、MHE を用いた自己位置推定手法、(2) 式を評価関数とした LRF 計測値のみを用いたマップマッチングによる推定手法¹⁹⁾、EKF を用いた推定手法、PF を用いた推定手法と真値を比較し、提案手法の推定精度を検証する。黒線で示したコース上をシミュレーション上で車両を走行させ、その結果を真値として扱う。自己位置推定に用いる LRF 計測値は、シミュレーション上で走行した際の車両の位置から、LRF で測定可能な環境地図上の点への距離情報とする。本論文で用いる LRF は Fig. 7 に示す北陽電機社製の UBG-04LX-F01 であり、その仕様を Table 1 に示す。

自己位置推定に利用する LRF 計測値には平均値 0、分散 $\sigma^2 = 1.92 \times 10^{-5}$ の正規性白色ノイズを加え、この値を MHE の重みにも用いる。このノイズの分散値は、予備実験で得た LRF 計測データを基に定めた。推定に用いる動作モデルにはシステムノイズとして、平均値 0、共分散 $\mathbf{Q} = \text{diag}(3.0 \times 10^{-6}, 3.0 \times 10^{-6}, 7.8 \times 10^{-7})$ の正規性白色

Table 2 Simulation condition

Initial state (x, y, θ)	$(3.0, 4.0, \pi)$
Vehicle Velocity V	0.3 m/s
Wheel base L	0.256 m
Threshold value ϵ	0.056 m
Field size $x \times y$	7 m $\times$ 5 m
Weight σ^2	1.92×10^{-5}
Weighting matrix Q	$\text{diag}(3.0 \times 10^{-6}, 3.0 \times 10^{-6}, 7.8 \times 10^{-7})$
Weighting matrix P	$\text{diag}(1.2 \times 10^{-6}, 1.2 \times 10^{-6}, 7.1 \times 10^{-7})$
Horizon H	3
Typical measurement number $\bar{N}$	44

ノイズ $\mathbf{v}_k$ を加えた。このシステムノイズの共分散は、実験車両を一定速度 $V = 0.3 \text{ m/s}$ で走行させた際の速度の分散を基に定め、この値を MHE の重みにも用いる。さらにオドメトリの累積誤差を発生させるために、推定に用いる車両速度に 0.015 m/s 、車両の操舵角に -0.02 rad のオフセットを加えた。これらの値は実験値を用いてオドメトリで推定した車両の走行軌跡に近くなるように試行錯誤的に決定した。また MHE に用いる重み行列 $\mathbf{P}$ はチューニングパラメータとし、車両を停止させた状態での自己位置推定値の分散を基準に設定した。MHE の評価区間長は実機の計算能力から $H = 3$ とした。また想定している環境の形状から、 y 座標の推定に必要な LRF 計測データ数よりも、 x 座標の推定に必要なデータ数のほうが少なくなる。そこで LRF 計測データ数の典型値はコースを走行した際に得られる x 座標を推定するための LRF 計測データ数の平均 $\bar{N} = 44$ とした。シミュレーション条件をまとめたものを **Table 2** に示す。比較手法の EKF を用いた手法では、LRF の距離計測値 1 つ 1 つを観測値に用いる。また PF を用いた手法では各パーティクルの重みを $w_l = \prod_{j=1}^N 1/(\sqrt{2\pi\sigma^2}) \exp(-0.5(\hat{r}(\hat{x}_{k,l}, \hat{y}_{k,l}, \hat{\theta}_{k,l}, \varphi_j) - r_j)^2/\sigma^2)$ 、パーティクル数を 200 とし、その重み付き平均値を各時刻の推定値とする。

5.4 シミュレーション結果

Fig. 5 に示す周囲が直線の壁のみに囲まれた環境での、オドメトリおよび MHE により推定した車両の走行軌跡を **Fig. 8 (a)** に示し、MHE によって推定した各状態の時間推移を **Fig. 8 (b)** に示す。Fig. 8 (a) より、オドメトリによる自己位置推定では累積誤差の影響を受け、時間推移とともに誤差が大きくなっていることが確認できる。一方で MHE による自己位置推定では真値と推定値がほぼ一致していることが確認できる。このことから、オドメトリの累積誤差の影響を抑えていることがわかる。提案手法と比較手法それぞれの推定値の誤差 RMS を **Table 3** に示す。表より、各推定値の誤差 RMS のオーダーは 10^{-3} m 、 10^{-3} rad 以下であり、7 m $\times$ 5 m の環境に比べ十分に小さい。さらに最適化計算を用いた手法である MHE と LRF 計測値を用いたマップマッチングによる手法の誤差 RMS が EKF と PF に比べて小さいことが確認できる。また Fig. 6 に示す周囲を直線の壁と円形の壁に囲まれた環境での、各手法の推定値の誤差 RMS を **Table 4** に示す。表より円形の壁が存在することで 1 つ目の環境に比べて誤差 RMS は増加しているが、この環境においても MHE と LRF 計測値を

Fig. 8 Simulation result of MHE: environment 1**Table 3** Error RMS: environment 1

Method	x [m]	y [m]	θ [rad]
MHE	6.97×10^{-4}	5.17×10^{-4}	2.51×10^{-4}
LRF	6.67×10^{-4}	5.35×10^{-4}	2.47×10^{-4}
EKF	7.16×10^{-3}	4.56×10^{-3}	4.65×10^{-3}
PF	1.94×10^{-3}	1.61×10^{-3}	8.65×10^{-4}

Table 4 Error RMS: environment 2

Method	x [m]	y [m]	θ [rad]
MHE	1.39×10^{-3}	1.03×10^{-3}	5.90×10^{-4}
LRF	6.30×10^{-3}	2.75×10^{-3}	1.03×10^{-3}
EKF	1.57×10^{-2}	8.10×10^{-3}	1.13×10^{-2}
PF	4.53×10^{-3}	2.85×10^{-3}	1.72×10^{-3}

用いたマップマッチングによる手法の誤差 RMS が EKF と PF に比べて小さい。MHE とマップマッチングによる手法では繰り返し計算により非線形の最適化問題を解くことで、高精度な自己位置推定を達成したと考えられる。またこれら 2 つの環境では LRF 計測値から自己位置推定に十分な情報が常に得られるため MHE とマップマッチングは同程度の推定精度となった。EKF では各サンプリングでシステムの線形化を必要とし、特に円形の壁を含む環境では非線形性が大きくなることで推定精度が悪化したと考えられる。PF ではパーティクルの数を増やすことで推定精度の向上が期待できるが、計算量の増加が問題となる。以上より、提案手法では同じく最適化計算を用いた手法であるマップマッチングと同程度で、EKF と PF に比べ高い推定精度をもつことを確認した。また Fig. 5 に示す環境において、各手法の数値シミュレーションを高精度な計算が可能なソフトウェアである Mathematica を用いて行なった。このとき MHE の最適化計算のソルバには

高速な CVXGEN を用いず、既存の一般的な最適化問題を解く関数である FindMinimum を用いた。用いたプロセッサは Intel Core i7-6700K CPU @ 4.00 GHz×8、メモリは 23.5 GB である。その結果 MHE による自己位置推定に要する平均計算時間は 0.13s、EKF はその約 0.23 倍、PF は約 24 倍となり、本条件では MHE は EKF に比べて大きく、PF に比べて小さい計算コストを要することが確認できた。

6. 特異環境における自己位置推定の検証

本章では数値シミュレーションにより、特異環境における提案手法の有効性を検証する。

6.1 シミュレーション条件

シミュレーション環境は Fig. 6 に示す周囲が直線の壁 W1, W2, W4 と円形の壁 W3 に囲まれた環境を想定する。ただし特異環境での自己位置推定の検証を行なうため、LRF の最大計測距離を 2.0 m とした。その他のシミュレーション条件は 5 章と同様とする。これにより $t = 0.0 \sim 3.4$ s の区間では W4 のみ、 $t = 3.4 \sim 6.7$ s の区間では W1 と W4、 $t = 6.7 \sim 11.0$ s の区間では W1 のみ、 $t = 11.0 \sim 14.3$ s の区間では W1 と W2、 $t = 14.3 \sim 17.7$ s の区間では W2 のみ、 $t = 17.7 \sim 24.7$ s の区間では W2 と W3、 $t = 24.7 \sim 35.2$ s の区間では W3 のみ、 $t = 35.2 \sim 40.7$ s の区間では W3 と W4、 $t = 40.7 \sim 47.3$ s の区間では W4 のみ、 $t = 47.3 \sim 50.0$ s の区間では W1 と W4 が LRF により観測できる。W1 からは車両の x と θ 、W2 と W4 からは y と θ 、W3 からは中心座標 (4.5 m, 2.5 m) で半径 2.5 m の円の半径方向の位置と姿勢の情報をもつ LRF 計測データが得られる。W1, W2, W4 のうちいずれか 1 つが観測される際は Fig. 2 (a)、W3 のみが観測される際は Fig. 2 (b) に示される特異環境を模擬している。上記の条件で MHE とマップマッチング、EKF、PF それぞれの手法による自己位置推定を行ない、特異環境での推定性能を検証する。

6.2 シミュレーション結果

Fig. 9 にマップマッチングと EKF、PF の推定結果、Fig. 10 に MHE の推定結果を示す。Fig. 9 の (a) は車両の走行軌跡、(b) は状態の時間推移、(c) は EKF の推定誤差の時間推移、(d) は PF の推定誤差の時間推移を示す。Fig. 10 の (a) は車両の走行軌跡、(b) は状態の時間推移、(c) は推定誤差の時間推移、(d) は W1, W2 と W4, W3 の各壁に対応付けられた LRF 計測データの数の時間推移を示す。灰色の区間は MHE で 1 つの壁のみが LRF で計測されたと判断された区間である。

まず Fig. 9 より、マップマッチングでは初期時刻から自己位置推定に失敗している。EKF では直線の壁のみが観測できる特異区間では自己位置を推定できているが、円形の壁が観測される区間 $t = 24.7 \sim 40.7$ s から徐々に推定誤差が増加し、2 つの直線の壁 W4 と W1 が観測される区間 $t = 47.3 \sim 50.0$ s でも対応付けに失敗し、誤差を修正できていない。PF では自己位置推定を達成しているが、EKF と同様に円形の壁が

Fig. 9 Simulation result of EKF and LRF: singular environment

観測される区間 $t = 24.7 \sim 40.7$ s では姿勢角の推定誤差が徐々に増加している。また Fig. 9 (d) より、 $t = 6.7 \sim 11.0$ s や $t = 14.3 \sim 17.7$ s の 1 つの直線の壁のみが観測できる特異区間に進入した際に、推定誤差が大きくなっていることが確認できる。これは特異方向の情報が尤度の計算に反映されず、その方向に平行な位置にあるすべての粒子に同様の重み付けがされたためだと考えられる。また EKF と PF では、 $t = 17.7 \sim 24.7$ s と $t = 35.2 \sim 40.7$ s の円形の壁と直線の壁が同時に観測され LRF 計測値から推定に十分な情報が得

られる区間でも、累積誤差が修正されていない。

Fig. 10 (a)(b) より、MHE では自己位置推定を達成している。(c) より、 $t = 0.0 \sim 3.4\text{s}$ と $t = 14.3 \sim 17.7\text{s}$ の LRF 計測データのみで x 座標を一意に決定できない区間、 $t = 6.7 \sim 11.0\text{s}$ の y 座標を一意に決定できない区間において、LRF 計測値では推定できない方向の位置はオドメトリの累積誤差の影響を受けている。しかしそれぞれの区間で LRF 計測値により推定できる方向の位置と姿勢角 θ は高精度に推定できている。また $t = 17.7 \sim 19.0\text{s}$ の区間では、W2 を計

(a) Trajectory.

(b) State.

(c) Error.

(d) Number of measuring data used for estimation.

Fig. 10 Simulation result of MHE: singular environment

測することで推定できる y, θ の推定値と、円形の壁 W3 に対する計測データが増えることで得られる x 座標の推定に有効な LRF 計測データを用いて、 x 座標の累積誤差が徐々に修正されている。また (a) より、 $t = 24.7 \sim 35.2\text{s}$ の円形の壁 W3 のみを計測できる区間では、LRF 計測データから円の半径方向の位置と姿勢の情報を用いることで、MHE では車両の走行経路の推定誤差を抑制できている。

以上より MHE では、特異環境においても LRF 計測値で得られない情報を動作モデルにより補い、同時最適化することで高精度な自己位置推定を達成している。

7. 実機実験

本章では、前章までに示した提案手法の有効性と実現可能性を実機実験により確認し、またリアルタイム制御に適用可能な計算量であることを示す。

7.1 実験システム

実験車両として Fig. 11 に示す ZMP 社製の RoboCar® を用いて検証する。その仕様を Table 5 に示す。RoboCar は前輪操舵後輪駆動の車両型ロボットであり、各車輪に取り付けられたロータリーエンコーダで得られる車輪の回転数から走行速度を計測し、車両上部に搭載した LRF で周囲物体までの距離を計測する。実験システムのブロック線図を Fig. 12 に示す。LRF から得られる計測値、ロータリーエンコーダか

Fig. 11 ZMP RoboCar equipped with LRF and in-wheel rotary encoders

Table 5 The specification of RoboCar

Manufacture	ZMP Inc.
Length × Width × Height	429.0 × 195.0 × 212.2 mm
Wheel base L	0.256 m
Internal sensor	Rotary encoder × 4
External sensor	Laser Range Finder
Main controller	AMD Geode LX800 Processor 500 MHz OS: Linux (Fedora 10)

Fig. 12 System block diagram

ら得られる速度，車両への指示操舵角を用いて MHE により車両の自己位置推定を行なう．そして推定値を用いて経路追従を達成するための車両速度および操舵角を制御器で求め，車両に入力する．車両の走行速度は一定値とし，操舵角は小山らの走行距離を時間軸とする時間軸状態制御形²¹⁾において仮想時間軸上で経路追従誤差を指数収束させる操舵角を用いる．また，すべての計算処理は車両に搭載されている動作周波数 500 MHz の組み込み CPU で行なっている．車両の制御周期は 15 ms であり，車両速度，入力操舵角の更新および自己位置推定も 15 ms ごとに行なう．一方で使用した LRF の走査周期は 28 ms のため，MHE による自己位置推定は 30 ms ごとに行ない，新たな LRF 計測データが取得できるまでは，その区間をオドメトリによって補間する．この条件において，シミュレーションと同じ Fig.5 および Fig.6 に示すそれぞれの環境で実機実験を行なう．MHE に用いる重みなどはシミュレーションと同様とする．またシミュレーションと同様に EKF，PF を用いた自己位置推定手法との比較を行ない提案手法の有効性を示す．比較手法では MHE を用いた実機実験で得られた車両の操舵角，速度，LRF 計測値の時系列データを用いてオフラインで自己位置を推定する．

7.2 自己位置推定精度の検証

まず Fig.5 に示す，LRF 計測データが常に十分に得られる環境で実機実験を行ない，提案手法の推定精度を検証する．オドメトリおよび EKF，MHE の推定結果を Fig.13 に示す．(a) に示す推定した走行軌跡より，オドメトリによる自己位置推定では累積誤差の影響を受け，時間推移とともに誤差が大きくなっている．一方で MHE，EKF，PF では自己位置推定を達成していることがわかる．このときの MHE と EKF，MHE と PF のそれぞれの推定値同士の誤差の時間推移を (c)(d) に示す．図より推定値同士の誤差のオーダーは 10^{-2} m， 10^{-2} rad であり，シミュレーションと同様に推定精度に差があるが，実験を行なった 7 m×5 m において十分に小さい．また (e) に示す自己位置推定およびそれを含みリアルタイム処理に要した計算時間より，MHE の最適化計算が制御周期以内に終了しており，リアルタイム制御に適用可能な手法であることを確認した．

7.3 特異環境における自己位置推定の検証

つぎに，Fig.6 に示す周囲が直線の壁 W1，W2，W4 と円形の壁 W3 に囲まれた環境において提案手法の検証を行なう．シミュレーションと同様に，特異環境における推定性能の検証を行なうために，計測距離が 2.0 m 以内の LRF 計測データのみを推定に用いた．推定結果を Fig.14 に示す．(a) には MHE，EKF，PF の推定走行軌跡，(b)(c) に MHE の推定値と，W1，W2 と W4，W3 の各壁に対応付けされた LRF 計測データ数の時間推移を示す．図中灰色の区間は MHE で推定する際に 1 つの壁のみを計測していると判断された区間を示す．(a) に示す推定した走行軌跡より，各手法で自己位置推定を継続できている．車両がフィールドの左上を走行している際，各手法で大きな推定誤差が生じている．これはオ

(a) Trajectory.

(b) State.

(c) Error between MHE and EKF.

(d) Error between MHE and PF.

(e) Computational time.

Fig.13 Experimental result

ドメトリの累積誤差により実際の走行軌跡と異なる経路が各手法で推定されたためであり，その後左側の壁 W1 を認識した際に推定誤差が修正されている．シミュレーションで確認できたように，EKF と PF では右上を走行する際に円形の

Fig. 14 Experimental result: singular environment

壁 W3 と直線の壁 W1 が同時に観測されても累積誤差を十分に修正できない。そのため EKF では W1 のみが観測されるフィールドの下側から左上に到達する間の累積誤差の影響で、大きな推定誤差が生じたと考えられる。PF では各粒子で異なる LRF 計測値と地図情報の対応付けが行なわれるため、EKF に比べ W1 を認識したと判断されやすくなることが考えられる。一方で、MHE ではフィールド右上を走行する際に W3 と W4 を同時に観測することで、その地点までの累積誤差が修正される。よって MHE と PF は EKF に比べ推定誤差を抑制できたと考えられる。また PF ではシミュレー

ションと同様に、フィールドの左下部分で特異区間に進入した際に x 座標の推定値が大きく変化していることが確認できる。(d) に自己位置推定およびそれを含むリアルタイム処理に要した計算時間を示す。図より円形の壁 W3 を観測している区間は、LRF 計測距離と円形の壁との対応付けのために計算時間が増加している。MHE による推定は制御周期以内に終了しており、この環境においてもリアルタイム制御に適用可能な手法であることを確認した。以上の結果より、特異環境において提案手法では従来手法に比べ累積誤差の影響を抑制した推定を達成できることを確認した。

8. 結 言

本論文では、最適化計算を用いたモデルベース推定手法である MHE を用いて、LRF 計測値を用いたマップマッチングとオドメトリを直接融合した自己位置推定手法を提案した。MHE の評価関数では LRF 計測値を用いたマップマッチングの推定誤差、オドメトリの推定誤差、初期値推定誤差の評価を行なう。一般にマップマッチングでは LRF 計測データから推定に用いる情報を多く得られない状態は、LRF の観測ノイズの影響を受けやすい。提案手法では LRF 計測データから得られる情報が少ない場合にはオドメトリを重視した推定が行なわれる。本論文では、LRF 計測データが十分に得られる環境において、比較手法である最適化計算を用いたマップマッチングと同程度で、EKF や PF による手法に比べ高い推定精度を提案手法が有することをシミュレーションと実機実験で確認した。さらにマップマッチングでは自己位置推定に失敗する特異環境においても、同時最適化によるマップマッチングとオドメトリの融合により、提案手法では EKF や PF に比べ累積誤差の影響を抑制した自己位置推定を達成できることをシミュレーションと実機実験で確認した。また実機実験により、本手法は実現可能であり、リアルタイム制御に適用可能な計算量であることを確認した。

本提案手法では、特異環境にあるか否かによって LRF 計測データ数やそこから得られる情報量が大きく変化する。よってこれを考慮した安定性の解析を行なう必要がある。また制約条件を扱えるという MHE の利点を用いることで提案手法の優位性の向上が期待できるため、これらを今後の課題としたい。

参 考 文 献

- 1) S. Thrun, W. Burgard and D. Fox: *Probabilistic Robotics*, 672, MIT Press (2005)
- 2) H. Durrant-Whyte and T. Bailey: Simultaneous localization and mapping: Part 1, *IEEE Robotics and Automation Magazine*, **13-2**, 99/110 (2006)
- 3) K. S. Chong and L. Kleeman: Accurate odometry and error modelling for a mobile robot, *Proc. of IEEE Robotics and Automation*, 2783/2788 (1997)
- 4) T. King, H. Fusler, M. Transier and W. Effelsberg: Dead-reckoning for position-based forwarding on highways, *Proc. of International workshop on intelligent transportation*, 199/204 (2006)

- 5) L. Teslic, I. Skrjanc and G. Klancar: Using a LRF sensor in the Kalman-filtering-based localization of a mobile robot, *ISA Trans.*, **49**-1, 145/153 (2010)
- 6) L. Chen, H. Hu and K. McDonald-Maier: EKF based mobile robot localization, *Proc. of 2012 Third International Conference on Emerging Security Technologies*, 149/154 (2012)
- 7) B. W. Kuo, H. H. Chang, Y. C. Chen and S. Y. Huang: A Light-and-Fast SLAM Algorithm for Robots in Indoor Environments Using Line Segment Map, *Journal of Robotics*, **2011**-257852, 1/12 (2011)
- 8) H. Kawata, A. Ohya and S. Yuta: Development of Compact and Light-weight LRF Based Positioning Sensor for Mobile Robot Localization, *Proc. of IEEE Advanced Robotics*, 1/6 (2009)
- 9) F. Lu and E. Milios: Robot pose estimation in unknown environments by matching 2D range scans, *Journal of Intelligent Robotics Systems*, **18**-3, 249/275 (1997)
- 10) A. Censi: An ICP variant using a point-to-line metric, *Proc. IEEE International Conference on Robotics and Automation*, 19/25 (2008)
- 11) 友納正裕: 移動ロボットのための確率的な自己位置推定と地図構築, 日本ロボット学会誌, **29**-5, 423/426 (2011)
- 12) O. Bengtsson and A.-J. Baerveldt: Robot localization based on scan-matching-estimating the covariance matrix for the IDC algorithm, *Robotics and Autonomous Systems*, **44**-1, 29/40 (2003)
- 13) A. Censi: On achievable accuracy for range-finder localization, *Proc. of IEEE International Conference on Robotics and Automation*, 4170/4175 (2007)
- 14) 岡谷貴之: バンドルアジャストメント, 情報処理学会研究報告, 2009-CVIM-167-37, 1/16 (2009)
- 15) E. L. Haseltine and J. B. Rawlings: Critical Evaluation of Extended Kalman Filtering and Moving-Horizon Estimation, *Proc. of Industrial and Engineering Chemistry Research*, **44**-8, 2451/2460 (2005)
- 16) J. Mattingley and S. Boyd: CVXGEN: A Code Generator for Embedded Convex Optimization, *Optimization and Engineering*, **13**-1, 1/27 (2012)
- 17) T. Ohtsuka: A Continuation/GMRES Method for Fast Computation of Nonlinear Receding Horizon Control, *Automatica*, **40**-4, 563/574 (2004)
- 18) S. Wang, L. Chen, D. Gu and H. Hu: An optimization based Moving Horizon Estimation with application to localization of Autonomous Underwater Vehicles, *Robotics and Autonomous Systems*, **62**-10, 1581/1596 (2014)
- 19) K. Kimura, Y. Hiromachi, K. Nonaka and K. Sekiguchi: Vehicle Localization by Sensor Fusion of LRS Measurement and Odometry Information based on Moving Horizon Estimation, *Proc. of Multi-Conference on Systems and Control 2014*, 1306/1311 (2014)
- 20) K. Sakaeta, K. Nonaka and K. Sekiguchi: Experimental Verification of a Vehicle Localization based on Moving Horizon Estimation Integrating LRS and Odometry, *Proc. of 13th Int. Conf. on Motion and Vibration Control*, 2522 (2016)
- 21) 小山, 野中, 関口: 走行距離を時間軸とする時間軸状態制御形による車両の経路追従制御—モデル予測車庫入れ制御への適用, 計測自動制御学会論文集, **50**-1, 746/754 (2014)

[著者紹介]

栄田 国志 (学生会員)

2017年東京都市大学工学研究科博士前期課程修了。同年横河ソリューションサービス(株)へ入社し現在に至る。在学中は前輪操舵型の車両ロボットを対象としたモデル予測制御や自己位置推定の研究に従事。

木村 一輝

2015年東京都市大学工学研究科博士前期課程修了。同年アズビル(株)へ入社し現在に至る。在学中は前輪操舵型の車両ロボットを対象としたモデル予測制御や自己位置推定の研究に従事。

野中 謙一郎 (正会員)

1997年東京工業大学情報理工学研究科博士課程修了。同年に武蔵工業大学(現・東京都市大学)工学部機械システム工学科助手。講師, 准教授を経て, 2013年から教授。2000年から1年間ボストン大学客員研究員。開ループ振動安定化, スライディングモード制御, ビークル制御に関する研究を行なう。

関口 和真 (正会員)

2010年東京工業大学大学院理工学研究科機械制御システム専攻博士後期課程修了(工学博士)。同年東京工業大学理工学研究科助教。2013年東京都市大学工学部助教, 2015年同大学講師となり現在に至る。微分幾何を用いた非線形システムの構造解析, 制御系設計の研究に従事。システム制御情報学会, IEEEの会員。