MAP-ICP: 最大事後確率推定により事前確率を考慮した 6 自由度 Iterative Closest Point マッチング

○原 祥尭 [*1]，阪東 茂 [*1]，坪内 孝司 [*1]，大島 章 [*2]，北原 格 [*1]，亀田 能成 [*1]

MAP-ICP: 6DOF Iterative Closest Point Matching using Maximum A Posteriori Estimation Considering Prior Probability

*Yoshitaka HARA[*1], Shigeru BANDO[*1], Takashi TSUBOUCHI[*1], Akira OSHIMA[*2], Itaru KITAHARA[*1], Yoshinari KAMEDA[*1]

[*1] Graduate School of Systems and Information Engineering, University of Tsukuba
1-1-1 Tennodai, Tsukuba, Ibaraki 305-8573, Japan
[*2] Doog Inc.
4-3-2 Ninomiya, Tsukuba, Ibaraki 305-0051, Japan

This paper claims that performance of point cloud registration between target and source cloud is effectively improved if we introduce maximum a posteriori estimation based on Bayes' theorem together with the initial pose and its covariance at the begining of the registration. Standard ICP approach for the registration sometimes falls into misconvergence arising from measurement errors, narrow field of view of sensors, movement of objects during measurement, and so on. Our approach will improve such problem. We evaluated our proposed method in three environments. The method successfully matches point clouds without the problem of misconvergence.

Key Words : Point Cloud, ICP Matching, Maximum A Posteriori Estimation, Bayes' Theorem

1. 緒　　言

車両の自律走行は重要な研究分野であり，自動車，無人搬送車，建機，パーソナルトランスポーター，移動ロボットなど，応用範囲が広い．DARPA Urban Challenge [(1)]や Google Self-Driving Car [(2)]では，正確な自己位置推定に基づく自動車の自律走行が実現された．これらの研究では，3D-LIDAR（レーザスキャナ）が主に使用されている．一方で近年，コンピュータの入力装置としての市場もある Depth Camera（距離画像カメラ）が発展し，安価な製品や太陽光下に対応した製品が登場するなど，3 次元測域センサの利用が広がっている．

自己位置推定には，車両に搭載した 3 次元測域センサで測定した Point Cloud データ（3 次元点群）を走行環境の地図（あるいは 1 時刻前のデータ）とマッチングする手法がよく用いられる．しかし従来のマッチング法では，センサの誤差や情報量の不足（測定範囲が狭い，周辺に測定対象物が少ない，など），アルゴリズムの近似誤差や仮定（静的環境を仮定など）の崩れ，一意に位置合わせできない形状などが原因で，過信（over-confidence）や過適合（over-fitting）と呼ばれる問題[(3) (4)]が発生し，正しい自己位置を推定できない場合があった．特に Depth Camera は視野角が狭く，過信が起こりやすい．この問題に対処するには，確率論に基づく Bayesian アプローチ[(4)]が有効であり，多数の手法が提案されている[(3)]．

筆者らは前稿[(5)]にて，最大事後確率推定（MAP：Maximum A Posteriori 推定）を用いた新たなマッチング法を定式化した．事前確率を評価関数に明示的に入れ，事前確率と計測の尤度の両方を考慮する．ベイズ推定を用いた従来手法[(3)]と同様の概念だが，異なるアプローチで解くことを試みている．本稿では前稿[(5)]で簡略化した部分をより一般的に定式化し，最大事後確率推定を用いた 6 自由度の Iterative Closest Point マッチングを実装して評価した．提案手法を，MAP-ICP と呼ぶ．本稿では自己位置推定を対象として評価したが，物体モデルの位置合わせなどにも利用可能である．

2. 関　連　研　究

点群のマッチングは，コンピュータビジョン分野で多く研究されている．文献[(6) (7)]では，特徴量を用いることで初期位置が不要な粗いマッチングや，初期位置ありで形状全体を用いた詳細マッチングの各手法を概観し

[*1] 筑波大学 大学院 システム情報工学研究科（〒 305-8573 茨城県つくば市天王台 1-1-1） hara.y@roboken.esys.tsukuba.ac.jp
[*2] 株式会社 Doog（〒 305-0051 茨城県つくば市二の宮 4-3-2）

て整理している．本稿で対象とする形状全体を用いた詳細マッチングは，ICP : Iterative Closest Point アルゴリズム[8][9]に代表される．Besl らの手法[8]では点対点対応（point-to-point）のマッチングを行い，Chen らの手法[9]では点対面対応（point-to-plane）のマッチングを行なっている．Segal らは，点対点対応や点対面対応の ICP を一般化して定式化した[10]．また Rusinkiewicz らは，対応付け方法や対応の重み付けと外れ値除去，誤差関数の定義や最適化手法などの観点で，ICP の様々な派生手法を比較評価した[11]．増田は文献[12]の中で，各種 ICP の定式化や収束性の議論も含めてより詳しく整理した．移動ロボットの自己位置推定に ICP を用いた研究としては，文献[13]〜[15]などがある．しかし ICP アルゴリズムは計測の尤度のみに基づく最小二乗法であり，過信や過適合の問題[3][4]で真値（ground truth）とは異なる誤った値を推定してしまう場合がある．

最小二乗法での過信の問題に対処するには，確率論に基づき事前確率と計測の尤度の両方を考慮する手法が有効である[4]．ロボティクス分野ではベイズ推定を用いた Bayes Filter による自己位置推定がよく用いられる[3]．Extended Kalman Filter は Bayes Filter のガウス分布による実装だが，任意形状のランドマークを利用することは難しく，基本的には対応関係が求まる点ランドマークや線ランドマークしか利用できない[3][16]．一方で Histogram Filter や Particle Filter は，任意形状の Point Cloud をグリッドなどで表現してランドマークとして利用できる[3]．Olson は Histogram Filter による相関を用いた自己位置推定[17]を高速化し，2 次元形状に対して 3 自由度のマッチングを実時間で行った[18]．しかしこの手法を 3 次元形状，6 自由度に適用する場合，計算コストが課題になると思われる．また Kummerle や Suzuki は，Particle Filter による Monte Carlo Localization [19]を 3 次元形状，6 自由度に適用した[20][21]．本研究では，これらと同様に確率論に基づいた 3 次元形状，6 自由度の自己位置推定を目的とするが，従来とは異なる最大事後確率推定によるアプローチで解くことを試み，性能を評価した．

3. 最大事後確率推定を用いたマッチング

本章では，提案手法である最大事後確率推定を用いたマッチングのアルゴリズムについて述べる．

3·1 定式化 提案手法の本質は，事前確率を評価関数に明示的に入れ，事前確率と計測の尤度の両方を考慮する点にある．事前確率には，オドメトリなどを用いる．従来の ICP ではオドメトリを使用する場合でも単なる繰り返し計算の初期位置としてであり，計測点群の重なりの尤度のみで表現されるマッチング評価値の場において局所解を求めていた．これに対し提案手法では，事前確率と計測の尤度を合わせた評価値の場において局所解を求めている．

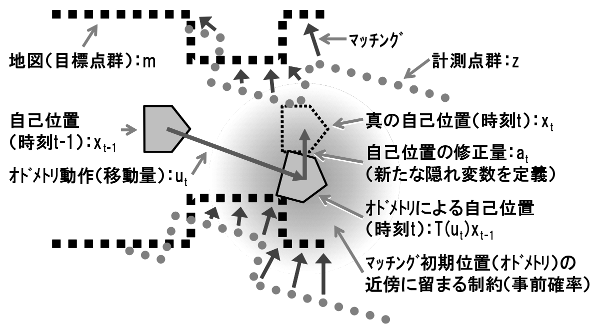

Fig. 1 A concept of the point cloud matching using maximum a posteriori estimation and the definitions of variables

図 1 に，最大事後確率推定を用いたマッチングの概念と各変数の定義を示す．提案手法では，事前確率である初期位置の近傍に留まる制約を与えてマッチングする．また事前確率を平均 **0** のガウス分布として扱うために，初期位置を原点とする座標系での自己位置の修正量を推定対象とした．すなわち自己位置 $\boldsymbol{x}_t$ を直接は推定せず，時刻 $t-1$ の自己位置 $\boldsymbol{x}_{t-1}$ にオドメトリによる移動量 $\boldsymbol{u}_t$ を加えた位置を初期位置とし，ここを座標系の原点とした修正量 $\boldsymbol{a}_t$ を推定して間接的に自己位置推定を行う．式 (1) に，各変数の関係を示す．

$$\hat{\boldsymbol{x}}_t = \boldsymbol{T}(\hat{\boldsymbol{a}}_t)\boldsymbol{T}(\boldsymbol{u}_t)\boldsymbol{x}_{t-1} \tag{1}$$

ここで，$\hat{\boldsymbol{x}}_t$ は時刻 t における自己位置 $\boldsymbol{x}_t$ の推定値，$\hat{\boldsymbol{a}}_t$ は時刻 t における自己位置の修正量 $\boldsymbol{a}_t$ の推定値，$\boldsymbol{T}(\hat{\boldsymbol{a}}_t)$ は修正量 $\boldsymbol{a}_t$ の同次変換行列，$\boldsymbol{T}(\boldsymbol{u}_t)$ はオドメトリによる移動量 $\boldsymbol{u}_t$ の同次変換行列である．

最大事後確率推定では，コストの大きさを表すエネルギー関数をベイズの定理に基づいて定義し，これを最小化することで推定を行う．提案手法のエネルギー関数 $E(\boldsymbol{a}_t)$ を式 (2) に示す．なお式 (2) の導出過程は，3·4 節にて述べる．

$$E(\boldsymbol{a}_t) = \frac{1}{K}\sum_{k=1}^{K}\left\|\boldsymbol{T}(\boldsymbol{a}_t)\boldsymbol{z}_{t,k} - \boldsymbol{m}_{c_{t,k}}\right\|^2 + \boldsymbol{a}_t^T\boldsymbol{\psi}\boldsymbol{a}_t \tag{2}$$

ここで，$\boldsymbol{z}_{t,k}$ は時刻 t に測定した Point Cloud の k 番目の点（計測点），K は計測点 $\boldsymbol{z}_{t,k}$ の点数，$\boldsymbol{m}_{c_{t,k}}$ は計測点 $\boldsymbol{z}_{t,k}$ に対応する地図上の点（目標点），$\boldsymbol{\psi}$ は正則化パラメータ行列と呼ぶ重み行列である．通常の ICP アルゴリズムの誤差関数とは，第 2 項 $+\boldsymbol{a}_t^T\boldsymbol{\psi}\boldsymbol{a}_t$ の部分が異なる．第 2 項は事前確率である初期位置から離れ過ぎない制約を与えており，文献[4]に拠れば正則化項（ペナルティ項）に該当する．正則化パラメータ行列

$\boldsymbol{\psi}$ は，3·4 節で詳細を述べるが，事前確率の共分散行列 $\boldsymbol{\Sigma}_a$ と計測の尤度の分散 σ_z^2 と計測点の点数 K を用いて式 (3) で定義する．

$$\boldsymbol{\psi} = \frac{\sigma_z^2}{K} \boldsymbol{\Sigma}_a^{-1} \tag{3}$$

よって式 (2) の正則化項は，正則化パラメータ行列 $\boldsymbol{\psi}$ に対する修正量 $\boldsymbol{a}_t$ のマハラノビス距離をノルムとして用いていると解釈できる．ここで修正量 $\boldsymbol{a}_t$ の回転成分 3 自由度のノルムの扱いが問題となるが，本稿では axis-angle 表現[22]での回転の大きさを用いた．このため，正則化パラメータ行列 $\boldsymbol{\psi}$ は並進 3 成分と回転 1 成分の 4×4 行列となる．

式 (2) に示したエネルギー関数 $E(\boldsymbol{a}_t)$ を式 (4) のように最小化する自己位置の修正量 $\boldsymbol{a}_t$ が，修正量の推定値 $\hat{\boldsymbol{a}}_t$ となる．推定した修正量 $\hat{\boldsymbol{a}}_t$ を式 (1) に代入することで，自己位置の推定値 $\hat{\boldsymbol{x}}_t$ を求める．

$$\hat{\boldsymbol{a}}_t = \underset{\boldsymbol{a}_t}{\operatorname{argmin}}\, E(\boldsymbol{a}_t) \tag{4}$$

3·2 MAP-ICP アルゴリズム　式 (4) の最小化には，各計測点 $\boldsymbol{z}_{t,k}$ に対応する目標点 $\boldsymbol{m}_{c_{t,k}}$ が分かる必要がある．本稿では形状全体を用いた詳細マッチングを目的とするため，距離が最小となる目標点（最近傍点）を対応点とし，通常の ICP アルゴリズムを拡張した以下の 3 つのステップの繰り返し計算によって式 (4) の最小化を行う．通常の ICP と異なるのは，ステップ 2) の非線形最適化の式のみである．なお前述のとおり，事前確率を平均 **0** のガウス分布として制約を与えるため，初期位置を原点とした座標系で計算する．

1) 最近傍探索による対応付け

前回の繰り返し計算での各計測点 $\hat{\boldsymbol{z}}_{t,k}^{(i-1)}$ を基準に，距離が最小となる地図上の目標点 $\boldsymbol{m}_{\hat{c}_{t,k}^{(i)}}$ を探索する．ここで，(i) は繰り返し計算回数（1,2,...），$\hat{c}_{t,k}^{(i)}$ は計測点 $\hat{\boldsymbol{z}}_{t,k}^{(i-1)}$ に対応する目標点 $\boldsymbol{m}$ の index の推定値である．$\hat{\boldsymbol{z}}_{t,k}^{(i-1)}$ は前回のステップ 3) で計算されている．ただし，$\hat{\boldsymbol{z}}_{t,k}^{(0)} = \boldsymbol{z}_{t,k}$（初期位置における計測点）である．

2) 非線形最適化による移動量の推定

求めた対応関係 $\hat{c}_{t,k}^{(i)}$ の下で，式 (5) と式 (6) に示す最小化により前回からの差分の移動量 $\hat{\boldsymbol{b}}_t^{(i)}$ を求める．

$$\hat{\boldsymbol{b}}_t^{(i)} = \underset{\boldsymbol{b}_t^{(i)}}{\operatorname{argmin}} \left\{ \frac{1}{K} \sum_{k=1}^{K} \left\| \boldsymbol{T}\left(\boldsymbol{b}_t^{(i)}\right) \hat{\boldsymbol{z}}_{t,k}^{(i-1)} - \boldsymbol{m}_{\hat{c}_{t,k}^{(i)}} \right\|^2 + \boldsymbol{a}_t^{(i)T} \boldsymbol{\psi} \boldsymbol{a}_t^{(i)} \right\} \tag{5}$$

$$\boldsymbol{a}_t^{(i)} = \boldsymbol{T}\left(\boldsymbol{b}_t^{(i)}\right) \hat{\boldsymbol{a}}_t^{(i-1)} \tag{6}$$

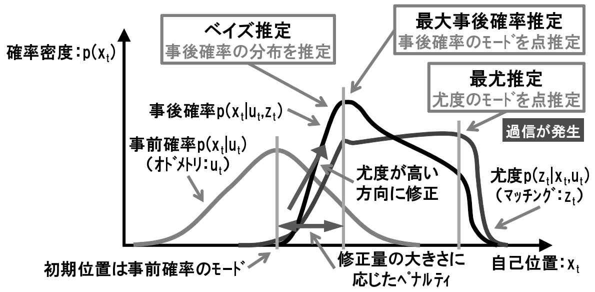

Fig. 2　A schematic view of probability distributions in Bayes' theorem for localization

本稿では式 (5) の最小化に，非線形最適化法である Levenberg-Marquardt 法[23]を用いた．

3) 移動量の適用と収束判定

自己位置の修正量 $\hat{\boldsymbol{a}}_t^{(i-1)}$ を推定した移動量 $\hat{\boldsymbol{b}}_t^{(i)}$ で座標変換し，$\hat{\boldsymbol{a}}_t^{(i)} = \boldsymbol{T}\left(\hat{\boldsymbol{b}}_t^{(i)}\right) \hat{\boldsymbol{a}}_t^{(i-1)}$ のように i 番目の繰り返し計算における自己位置の修正量の推定値 $\hat{\boldsymbol{a}}_t^{(i)}$ を求める．ただし，$\hat{\boldsymbol{a}}_t^{(0)} = \boldsymbol{0}$ である．また各計測点 $\hat{\boldsymbol{z}}_{t,k}^{(i-1)}$ を，$\hat{\boldsymbol{z}}_{t,k}^{(i)} = \boldsymbol{T}\left(\hat{\boldsymbol{b}}_t^{(i)}\right) \hat{\boldsymbol{z}}_{t,k}^{(i-1)}$ のように推定した移動量 $\hat{\boldsymbol{b}}_t^{(i)}$ で座標変換する．移動量 $\hat{\boldsymbol{b}}_t^{(i)}$ が充分に小さく収束した場合，または繰り返し計算回数 (i) が閾値に達した場合は終了し，そうでない場合はステップ 1) に戻る．

以上の繰り返し計算の結果，式 (2) のエネルギー関数 $E(\boldsymbol{a}_t)$ が最小化され，計測点群が目標点群にマッチングする．また修正量の推定値 $\hat{\boldsymbol{a}}_t^{(i)}$ を式 (1) に代入することで，自己位置の推定値 $\hat{\boldsymbol{x}}_t$ が求まる．

3·3 ベイズ推定を用いた自己位置推定法との比較

提案手法を文献[4]に従って確率論で考えると，次の意味を持つ．まずベイズの定理を基本的な自己位置推定問題に適用すると，式 (7) となる．

$$p(\boldsymbol{x}_t \mid \boldsymbol{u}_t, \boldsymbol{z}_t) = \eta\ p(\boldsymbol{z}_t \mid \boldsymbol{x}_t, \boldsymbol{u}_t)\ p(\boldsymbol{x}_t \mid \boldsymbol{u}_t) \tag{7}$$

$p(\boldsymbol{x}_t \mid \boldsymbol{u}_t, \boldsymbol{z}_t)$ が自己位置の事後確率，$p(\boldsymbol{z}_t \mid \boldsymbol{x}_t, \boldsymbol{u}_t)$ が計測の尤度，$p(\boldsymbol{x}_t \mid \boldsymbol{u}_t)$ がオドメトリによる事前確率，η は正規化係数である．**図 2** に，式 (7) を 1 次元の自己位置で考えた場合の確率密度のグラフを示す．従来の ICP などの最尤推定（最小二乗法と等価）では，尤度を最大にする値を推定値とする．尤度のみを用いるため，過信が起こりやすい．一方で最大事後確率推定とベイズ推定は，事後確率を推定する．尤度と事前確率を考慮するため，過信が起こりにくい．提案手法では最大事後確率推定を用い，尤度が高く，かつ事前確率のモードから離れすぎない自己位置を探索している．

ベイズ推定を用いた Bayes Filter による自己位置推定では，式 (8) のようにベイズの定理を適用する．さらに自己位置の時系列をマルコフ過程としてとらえ，

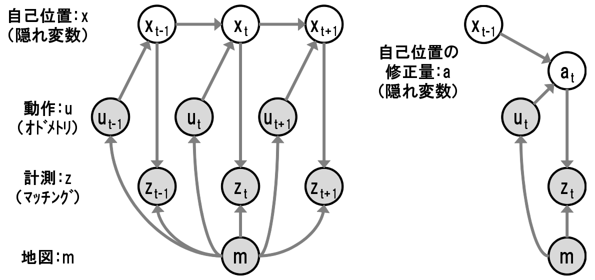

(a) Bayes Filter　　(b) Our method

Fig. 3　Graphical models for localization

全確率の定理により式 (9) が求まる．この式 (9) が，Bayes Filter による自己位置推定を表す．

$$
\begin{aligned}
&p(\boldsymbol{x}_t \,|\, \boldsymbol{u}_{1:t}, z_{1:t}, \boldsymbol{m}) \\
&= \eta\ p(z_t \,|\, \boldsymbol{x}_t, \boldsymbol{u}_{1:t}, z_{1:t-1}, \boldsymbol{m})\ p(\boldsymbol{x}_t \,|\, \boldsymbol{u}_{1:t}, z_{1:t-1}, \boldsymbol{m}) \qquad (8)\\
&= \eta\ p(z_t \,|\, \boldsymbol{x}_t, \boldsymbol{m}) \\
&\quad \times \int p(\boldsymbol{x}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{m})\ p(\boldsymbol{x}_{t-1} \,|\, \boldsymbol{u}_{1:t-1}, z_{1:t-1}, \boldsymbol{m}) d\boldsymbol{x}_{t-1} \qquad (9)
\end{aligned}
$$

確率論のグラフィカルモデル[4]で自己位置推定を表すと，**図 3** となる．**図 3(a)** が Bayes Filter，**図 3(b)** が提案手法である．Bayes Filter では，自己位置の時系列をマルコフ過程としてベイズの定理を適用している．これに対して提案手法では，時系列ではなくある時刻の自己位置推定の問題を考え，また事前確率を平均 **0** のガウス分布として扱うために新たな隠れ変数として自己位置の修正量を導入してベイズの定理を適用している点が異なる．なお図 2 に示したように，Bayes Filter では自己位置の事後確率を分布として求めるが，提案手法では事後確率のモード（最頻値）のみを点推定している．事後確率の分布が必要な場合には，ラプラス近似[4]などの枠組みで計算すれば良い．

3·4　エネルギー関数の導出過程　　式 (2) に示した提案手法のエネルギー関数 $E(\boldsymbol{a}_t)$ の導出過程を示す．提案手法は図 3(b) に示したように，ある時刻の自己位置推定の問題を自己位置の修正量の推定問題として定式化している．図 3(b) のグラフィカルモデルにベイズの定理を適用することで，式 (10) が求まる．

$$
\begin{aligned}
&p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, z_t, \boldsymbol{m}) \\
&\quad = \eta\ p(z_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m})\ p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{m}) \qquad (10)
\end{aligned}
$$

最大事後確率推定を用いるため，式 (10) の事後確率を最大化することで，式 (11) のように自己位置の修正量 $\boldsymbol{a}_t$ を推定する．

$$
\hat{\boldsymbol{a}}_t = \underset{\boldsymbol{a}_t}{\operatorname{argmax}}\ p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, z_t, \boldsymbol{m}) \qquad (11)
$$

尤度分布として対応点間距離のガウス分布を仮定すると，式 (12) となる．$S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, z_{t,k})$ は，最近傍探索の関数である．

$$
\begin{aligned}
&p(z_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}) \\
&\quad = \prod_{k=1}^{K} \mathcal{N}\left(z_{t,k} \,|\, S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, z_{t,k}), \boldsymbol{\Sigma}_z\right) \qquad (12)
\end{aligned}
$$

尤度分布の共分散行列 $\boldsymbol{\Sigma}_z$ が等方共分散行列[4]（スカラー行列）だと仮定すると，$\boldsymbol{\Sigma}_z = \sigma_z^2 \boldsymbol{I}$ となる．すると式 (12) は式 (13) のように展開できる．なお $z'_{t,k}$ は，$z'_{t,k} = \boldsymbol{T}(\boldsymbol{a}_t) z_{t,k}$ のように自己位置の修正量 $\boldsymbol{a}_t$ で計測点 $z_{t,k}$ を座標変換した点を意味する．また M は，計測点 $z_{t,k}$ の次元である．3 次元形状の場合，3 となる．

$$
\begin{aligned}
&p(z_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}) \\
&= \prod_{k=1}^{K} \frac{1}{\left(\sqrt{2\pi\sigma_z^2}\right)^M} \\
&\qquad \times \exp\left\{ -\frac{1}{2\sigma_z^2} \left\| z'_{t,k} - S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, z_{t,k}) \right\|^2 \right\} \qquad (13)
\end{aligned}
$$

また自己位置の修正量の事前確率を平均 **0** のガウス分布だと仮定すると，式 (14) となる．

$$
p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{m}) = \mathcal{N}(\boldsymbol{a}_t \,|\, \boldsymbol{0}, \boldsymbol{\Sigma}_a) \qquad (14)
$$

式 (14) は式 (15) のように展開できる．なお N は，修正量 $\boldsymbol{a}_t$ の次元である．3 次元空間での移動の場合，6 自由度となる．

$$
p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{m}) = \frac{1}{\left(\sqrt{2\pi}\right)^N} \frac{1}{\sqrt{|\boldsymbol{\Sigma}_a|}} \exp\left(-\frac{1}{2} \boldsymbol{a}_t^T \boldsymbol{\Sigma}_a^{-1} \boldsymbol{a}_t \right) \qquad (15)
$$

ここで式 (11) のように事後確率を最大化することは，事後確率の自然対数をとって符号反転した式を最小化することに等しいので，式 (16) とできる．

$$
\hat{\boldsymbol{a}}_t = \underset{\boldsymbol{a}_t}{\operatorname{argmin}} - \ln p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, z_t, \boldsymbol{m}) \qquad (16)
$$

式 (16) に従って式 (10) の自然対数をとって符号反転し，式 (13) と式 (15) を代入すると，式 (17) が求まる．

$$
\begin{aligned}
&-\ln\ p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, z_t, \boldsymbol{m}) \\
&= -\ln p(z_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}) - \ln p(\boldsymbol{a}_t \,|\, \boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{m}) - \text{const.} \\
&= \frac{MK}{2} \ln\left(2\pi\sigma_z^2\right) + \frac{1}{2\sigma_z^2} \sum_{k=1}^{K} \left\| z'_{t,k} - S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, z_{t,k}) \right\|^2 \\
&\quad + \frac{N}{2} \ln(2\pi) + \frac{1}{2} \ln|\boldsymbol{\Sigma}_a| + \frac{1}{2} \boldsymbol{a}_t^T \boldsymbol{\Sigma}_a^{-1} \boldsymbol{a}_t - \text{const.} \qquad (17)
\end{aligned}
$$

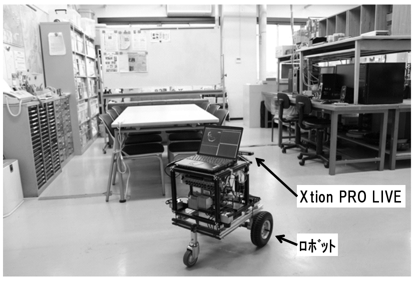

Fig. 4　An experimental environment to investigate the influence of complex shapes

Fig. 5　An experimental environment to investigate the influence of featureless shapes

Fig. 6　An experimental environment to investigate the influence of moved objects

式 (17) から定数項を除き，重み付けのパラメータをまとめるために $\frac{2\sigma_z^2}{K}$ を掛けた式をエネルギー関数として定義すると，式 (18) が求まる．ここで正則化パラメータ行列 $\boldsymbol{\psi}$ は，式 (3) に示したものである．さらに計測点 $\boldsymbol{z}_{t,k}$ の座標変換を考慮して最近傍探索の関数 $S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, \boldsymbol{z}_{t,k})$ を展開すると，式 (19) が求まる．

$$E(\boldsymbol{a}_t) = \frac{1}{K}\sum_{k=1}^{K}\left\| \boldsymbol{z}'_{t,k} - S(\boldsymbol{x}_{t-1}, \boldsymbol{u}_t, \boldsymbol{a}_t, \boldsymbol{m}, \boldsymbol{z}_{t,k})\right\|^2 + \boldsymbol{a}_t^T \boldsymbol{\psi} \boldsymbol{a}_t \tag{18}$$

$$= \frac{1}{K}\sum_{k=1}^{K}\left\| \boldsymbol{T}(\boldsymbol{a}_t)\boldsymbol{z}_{t,k} - \boldsymbol{m}_{c_{t,k}}\right\|^2 + \boldsymbol{a}_t^T \boldsymbol{\psi} \boldsymbol{a}_t \tag{19}$$

以上の計算により，式 (2) に示した提案手法のエネルギー関数 $E(\boldsymbol{a}_t)$ を導出した．

4. 実　　験

通常の ICP と提案手法である MAP-ICP を比較評価するため，Depth Camera として ASUS 製の Xtion PRO LIVE を搭載したロボットで実験を行った．Xtion の視野角は水平 58 [deg]，垂直 45 [deg] と狭く，過信が起こりやすい．評価方法は，真値に対して並進と回転の誤差をそれぞれ独立に加えた複数のマッチング初期位置を条件にとり，マッチングによる自己位置推定の誤差を評価した．本稿では，初期位置に与える誤差は y 軸方向（ロボットの左右方向）の並進の誤差と yaw 回転の誤差とした．自己位置推定の誤差としては，推定位置の並進誤差は真値からの距離，推定位置の回転誤差は axis-angle 表現[22]での真値からの回転の大きさを用いて評価した．

ICP は誤差メトリック（式 (2) や式 (5) の第 1 項のノルム）の定義によって性質が変化する[12]ため，点対点対応[8]と点対面対応[9]について実験を行った．点対面対応では，各目標点の近傍 0.2 [m] 以内の点群を用いて法線を算出した．点対点対応と点対面対応のそれぞれにおいて，通常の ICP，MAP-ICP，通常の ICP に RANSAC [24]を併用したもの，MAP-ICP に RANSAC を併用したもの，の 4 種類を比較対象とした．通常の ICP および通常の ICP に RANSAC を併用したものは，Point Cloud Library[25]の実装を用いた．いずれの手法も，対応点間距離の最大値（閾値）は 1.0 [m] に設定した．RANSAC の外れ値除去の閾値は，0.2 [m] とした．また MAP-ICP の正則化パラメータ行列 $\boldsymbol{\psi}$ は対角行列とし，x 成分：$\exp(-100)$，y 成分：$\exp(-100)$，z 成分：$\exp(-5)$，axis-angle 成分：$\exp(-3)$ とした．x 成分と y 成分については，非常に弱い制約としている．なお自己位置の修正量 $\boldsymbol{a}_t$ の並進成分の単位は [m]，回転成分の単位は [rad] である．

実験環境は以下の 3 種類とした．複雑な形状に対する性質を調べるための，机や PC などの雑多なものが置かれた部屋環境（**図 4**）．単純な形状に対する性質を調べるための，特徴の少ない大きな平面のみで構成された廊下環境（**図 5**）．そして移動した物体の影響を調べるため，目標点群の測定時と計測点群の測定時の間に測定対象物の位置を人が動かした動的な環境（**図 6**）．図 6 の段ボール箱とゴミ箱を，目標点群の測定後に左に 0.5 [m] 程度移動してから計測点群を測定した．

図 7，**図 10**，**図 13** に，それぞれの環境で真値を初期位置とした場合（初期位置の誤差がゼロの場合）の通常の ICP と MAP-ICP のマッチング結果を示す．いずれも点対面対応である．各図において，黒色が目標点群を，灰色が計測点群を表している．この結果を見ると，図 7 の複雑な形状の環境では通常の ICP と MAP-ICP で共に正しくマッチングできている．しかし図 10 の形状に特徴が少なく，また Depth Camera の視野角が狭いために目標点群と計測点群で共通する領域が少ない条件では，通常の ICP は誤った位置に収束してしまっている．これに対し MAP-ICP は，床面や柱が水平・垂直を保って正しい位置にマッチングした．また図 13 の移動した物体が存在する動的な環境では，通常の ICP は移動した物体の影響を受けて床面が傾いてマッチングしてしまったが，MAP-ICP では事前確率から離れ過ぎない制約の範囲で，移動していない床面

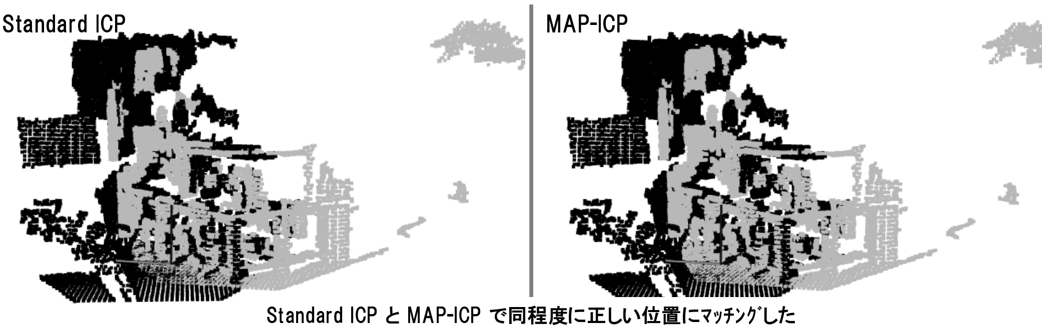

Fig. 7　An example of matching results of standard ICP and MAP-ICP in the room environment

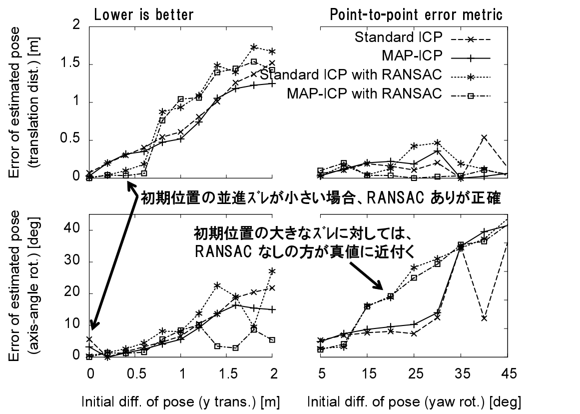

Fig. 8　Errors of estimated pose using point-to-point matching in the room environment

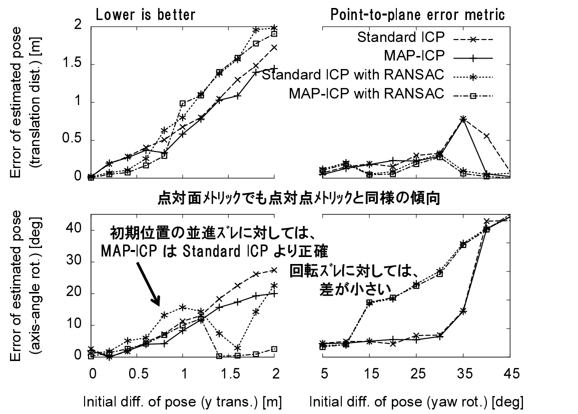

Fig. 9　Errors of estimated pose using point-to-plane matching in the room environment

や壁が良く重なる位置にマッチングできている．

図 8 と**図 9** に，図 4 の部屋環境での自己位置推定の誤差評価結果を示す．図 8 が点対点対応，図 9 が点対面対応である．点対点対応と点対面対応のいずれも，初期位置の誤差が小さい場合には RANSAC ありの方が正確なマッチングができている．初期位置の並進ズレにおいて，特に顕著である．しかし初期位置の誤差が大きい場合には，RANSAC ありでは初期位置からあまり修正されず，大きな誤差が残ってしまっている．また通常の ICP と MAP-ICP を比較すると，初期位置が真値に近い場合に MAP-ICP の方が誤差が小さい傾向があるが，大きな違いはないようである．

図 11 と**図 12** に，図 5 の廊下環境での自己位置推定の誤差評価結果を示す．図 11 が点対点対応，図 12 が点対面対応である．点対点対応では，初期位置の誤差がゼロの場合でも RANSAC なしでは誤った位置に収束している．MAP-ICP は RANSAC なしでも通常の ICP より誤差は小さいが，5 [deg] 程度の誤差が発生してしまっている．一方で初期位置に回転ズレがある場合，RANSAC ありの方が誤差が大きくなっている箇所もある．点対面対応では，真値が初期位置でも通常の ICP は誤った位置に収束しているのに対し，MAP-ICP は RANSAC なしでも正しくマッチングできている．また点対点対応と点対面対応の両方で，全体的に初期位置が真値に近い場合には MAP-ICP の方が正確な自己位置推定ができている．

図 14 と**図 15** に，図 6 の移動した物体が存在する動的な環境での自己位置推定の誤差評価結果を示す．図 14 が点対点対応，図 15 が点対面対応である．点対点対応と点対面対応で共に，真値が初期位置でも通常の ICP は誤った位置に収束しているのに対し，MAP-ICP の方が誤差が小さくなっている．また全体的に，初期位置が真値に近い場合には MAP-ICP の方が正確な自己位置推定ができている．

以上の実験結果から，点対点対応と点対面対応のいずれにおいても，初期位置が真値に近い場合には MAP-ICP に RANSAC を併用したものが最も正確にマッチングを行えている．形状に特徴が少なく，かつ目標点群と計測点群で共通する領域が少なかったり，移動した物体が存在するなどの厳しい条件においても，初期位置の並進ズレが 0.6 [m]，回転ズレが 10 [deg] 程度以内であれば，並進誤差 0.3 [m]，回転誤差 5 [deg] 程度の自己位置推定ができている．充分に複雑な形状の環境では，同様の初期位置の条件で並進誤差 0.2 [m]，回転誤差 4 [deg] 未満で自己位置推定ができている．提案手法の MAP-ICP では最大事後確率推定により事前

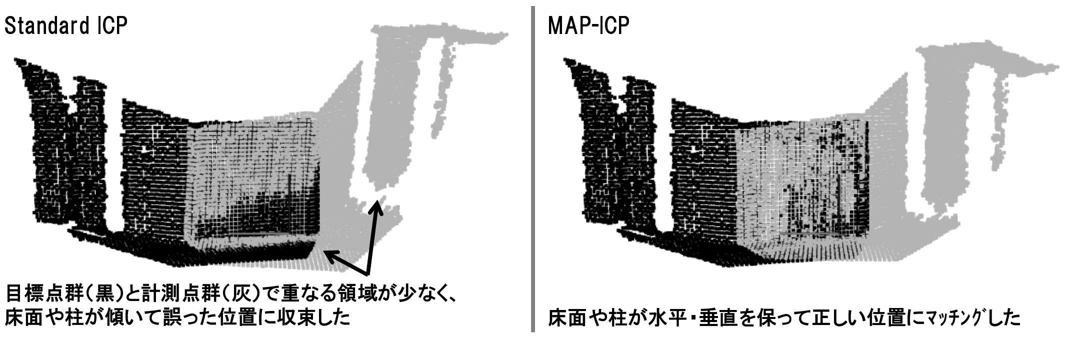

Fig. 10　An example of matching results of standard ICP and MAP-ICP in the hallway environment

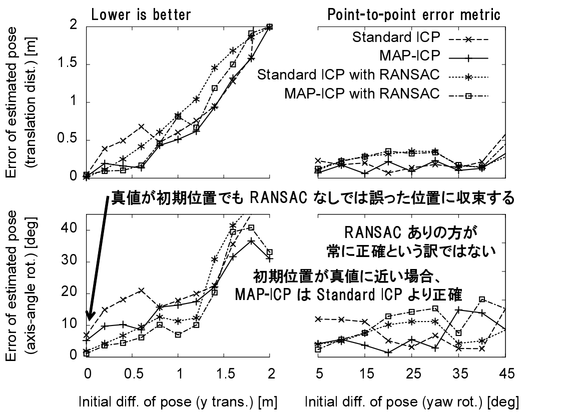

Fig. 11　Errors of estimated pose using point-to-point matching in the hallway environment

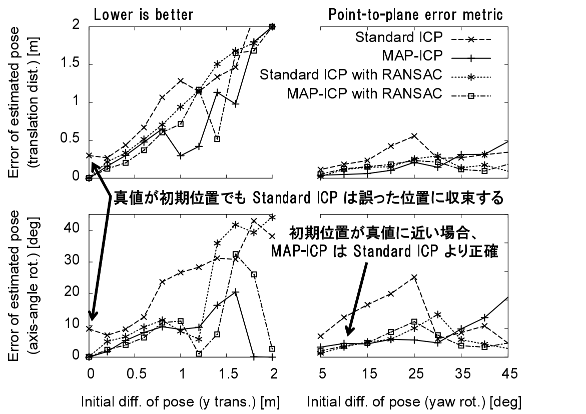

Fig. 12　Errors of estimated pose using point-to-plane matching in the hallway environment

確率と計測の尤度の両方を考慮することで，測定距離の誤差が大きく視野角が狭い Depth Camera を用いた自己位置推定においても通常の ICP より正確なマッチングを実現した．

5. 結　　言

本稿では，3 次元測域センサの計測点群を目標点群（地図）とマッチングする自己位置推定を対象とした．従来のマッチング法では，センサの誤差や情報量の不足，アルゴリズムの近似誤差や仮定の崩れ，一意に位置合わせできない形状などが原因で，過信や過適合と呼ばれる問題が発生し，正しい自己位置を推定できない場合があった．特に Depth Camera は視野角が狭く，過信が起こりやすい．そこで本稿では，最大事後確率推定により事前確率をマッチング評価式に明示的に入れ，事前確率と計測の尤度の両方を考慮したマッチングを実現した．実験の結果，通常の ICP では正確な自己位置推定が困難な状況であっても，提案手法の MAP-ICP では推定位置の誤差が小さいマッチングが可能であることを確認した．本稿では自己位置推定を対象としたが，MAP-ICP は物体モデルの位置合わせなどにも利用可能である．

謝　　辞

本研究は JSPS 特別研究員奨励費 24・2589 の助成を受けた．

参 考 文 献

(1) Martin Buehler, Karl Iagnemma, and Sanjiv Singh : “The DARPA Urban Challenge”, *Springer*, 2010.

(2) John Markoff : “Google Cars Drive Themselves, in Traffic”, *New York Times*, 2010. http://www.nytimes.com/2010/10/10/science/10google.html

(3) Sebastian Thrun, Wolfram Burgard, and Dieter Fox : “Probabilistic Robotics”, *The MIT Press*, 2005.

(4) Christopher M. Bishop : “Pattern Recognition and Machine Learning”, *Springer*, 2006.

(5) 原 祥尭, 阪東 茂, 坪内 孝司 : “Bayesian アプローチに基づき過信を防いだ Point Cloud マッチングによる自己位置推定の定式化”, *Proc. of RSJ2012*, 2012.

(6) 増田 健, 岡谷（清水）郁子, 佐川 立昌 : “距離データ処理 - 複数距離画像からの形状モデル生成技術”, *Proc. of the 146th CVIM*, 2004.

(7) Joaquim Salvi, Carles Matabosch, David Fofi, and Josep Forest : “A Review of Recent Range Image Registration Methods with Accuracy Evaluation”, *J. of Image and Vision Computing*, Vol.25, No.5, pp.578–596, 2007.

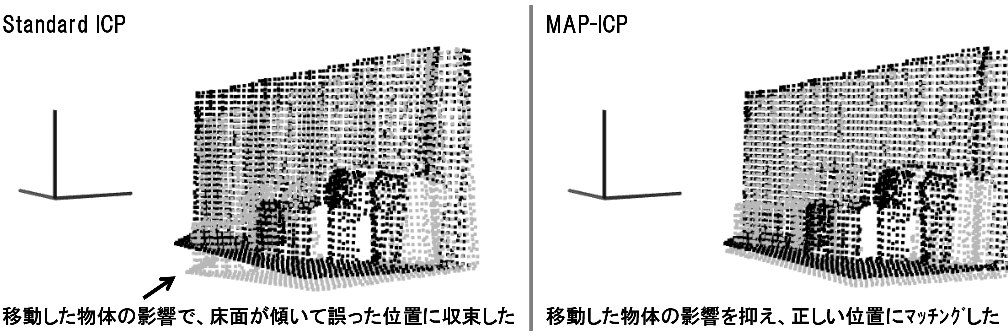

Fig. 13　An example of matching results of standard ICP and MAP-ICP in the moved objects environment

(8) Paul J. Besl, and Neil D. McKay : "A Method for Registration of 3-D Shapes", *IEEE Trans. on PAMI*, Vol.14, No.2, pp.239–256, 1992.

(9) Yang Chen, and Gerard Medioni : "Object Modeling by Registration of Multiple Range Images", *J. of Image and Vision Computing*, Vol.10, No.3, pp.145–155, 1992.

(10) Aleksandr V. Segal, Dirk Haehnel, and Sebastian Thrun : "Generalized-ICP", *Proc. of RSS2009*, 2009.

(11) Szymon Rusinkiewicz, and Marc Levoy : "Efficient Variants of the ICP Algorithm", *Proc. of 3DIM2001*, 2001.

(12) 八木 康史, 斎藤 英雄, et al. : "コンピュータビジョン最先端ガイド 3", アドコム・メディア, 2010.

(13) Feng Lu, and Evangelos Milios : "Robot Pose Estimation in Unknown Environments by Matching 2D Range Scans", *J. of Intelligent and Robotic Systems*, Vol.18, No.3, pp.249–275, 1997.

(14) Andreas Nuchter, Kai Lingemann, Joachim Hertzberg, and Hartmut Surmann : "6D SLAM - 3D Mapping Outdoor Environments", *J. of Field Robotics*, Vol.24, No.8–9, pp.699–722, 2007.

(15) 原 祥尭, 大島 章, 小野 幸彦, 網野 梓, 山本 健次郎 : "人込み歩道環境に適応した自律移動技術の開発と実験機 Sofara-T を用いた実環境での評価", 日本ロボット学会誌, Vol.30, No.3, pp.287–295, 2012.

(16) 金井 喜美雄, et al. : "ビークル", 計測自動制御学会, コロナ社, 2003.

(17) Kurt Konolige, and Ken Chou : "Markov Localization using Correlation", *Proc. of IJCAI1999*, 1999.

(18) Edwin Olson : "Real-Time Correlative Scan Matching", *Proc. of ICRA2009*, 2009.

(19) Frank Dellaert, Dieter Fox, Wolfram Burgard, and Sebastian Thrun : "Monte Carlo Localization for Mobile Robots", *Proc. of ICRA1999*, 1999.

(20) Rainer Kummerle, Rudolph Triebel, Patrick Pfaff, and Wolfram Burgard : "Monte Carlo Localization in Outdoor Terrains using Multi-Level Surface Maps", *J. of Field Robotics*, Vol.25, No.6–7, pp.346–359, 2008.

(21) Taro Suzuki, Yoshiharu Amano, and Takumi Hashizume : "6-DOF Localization for a Mobile Robot using Outdoor 3D Point Clouds", *J. of Robotics and Mechatronics*, Vol.22, No.2, pp.158–166, 2010.

(22) Fletcher Dunn, and Ian Parberry : "3D Math Primer for Graphics and Game Development", *CRC Press*, 2011.

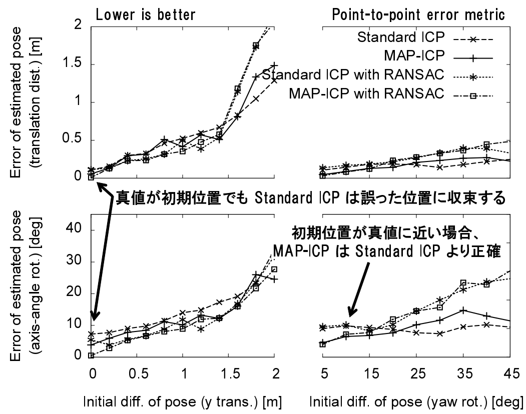

Fig. 14　Errors of estimated pose using point-to-point matching in the moved objects environment

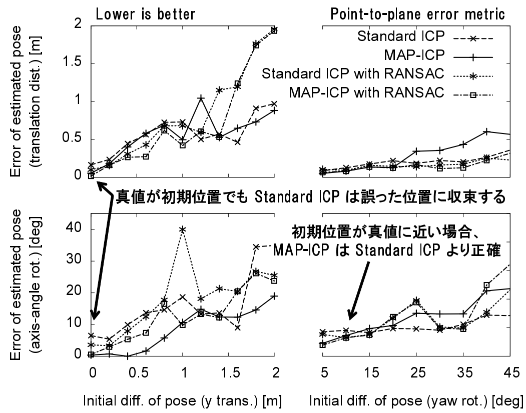

Fig. 15　Errors of estimated pose using point-to-plane matching in the moved objects environment

(23) 金谷 健一 : "これなら分かる最適化数学", 共立出版, 2005.

(24) Martin A. Fischler, and Robert C. Bolles : "Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography", *Comm. of the ACM*, Vol.24, No.6, pp.381–395, 1981.

(25) Point Cloud Library.
`http://pointclouds.org/`