

建造物の壁に対する相対姿勢を用いたリアルタイム 6DoF 位置姿勢推定

尾崎 亮太^{*1}, 黒田 洋司^{*2}

Real-time 6DoF localization with relative poses to walls of buildings

Ryota OZAKI^{*1} and Yoji KURODA^{*2}^{*1,*2} Department of Mechanical Engineering, School of Science and Technology, Meiji University
1-1-1 Higashimita, Kawasaki Tama-ku, Kanagawa 214-8571, Japan

Received: 13 February 2019; Revised: 6 May 2019; Accepted: 5 June 2019

Abstract

This paper presents a real-time 6DoF localization method which corrects accumulative error by estimating relative poses to building walls for mobile robots in urban areas. This method exploits a fact that most of all artificial walls are built vertically. It estimates poses by not only an inertial sensor but also real-time SLAM and observations of normals from point-cloud of artificial walls for estimating absolute poses in the gravity coordinate system. Those three types of poses which are estimated by each way are combined by extended Kalman filter. To evaluate the proposed method, outdoor experiments with an actual robot were performed. They show the method keeps correcting accumulative error while the robot moves. The other experiments show how the method suppresses influence of non-vertical planes.

Keywords : Pose estimation, 6DoF localization, Mobile robot, Artificial environment, Gauss map, Extended Kalman filter

1. 緒 言

近年、屋内や市街地のような整備された人工環境において活動する自律移動ロボットへの需要が高まっている。また、次世代の移動ロボットは、その適用範囲を広げるため、高い機動性を持つことが要求される。高い機動性を実現するための手段の1つとして姿勢制御があり、実際に開発されている (Kwon et al., 2015)。移動ロボットの姿勢制御を行うには、走行中における時々刻々の3次元空間におけるロボットの自己姿勢を推定し把握し続ける必要がある。ここで、本論文では、重力方向ベクトルに対するロボットの傾きを姿勢と呼ぶこととする。なお、この姿勢をワールド座標系で表現する場合は、重力ベクトルに対するロール、ピッチに加えて、ヨーも必要となる。

移動体の姿勢は、一般に、ジャイロ스코プや加速度センサを使って推定することが多い。地面上を走行する移動ロボットの場合、ロボット自身の加速度や地面からの振動が推定精度に大きな影響を与えるため、さらに外界センサを用いた SLAM (Simultaneous Localization and Mapping) (Thrun et al., 2005) との組み合わせが提案されている (Stumberg et al., 2018)。姿勢を推定するための SLAM として、ICP スキャンマッチング (Rusinkiewicz and Levoy, 2001) や NDT スキャンマッチング (Biber and Straßer, 2003)(Magnusson et al., 2007) を用いた SLAM が代表的である。これらのスキャンマッチングでは、2つの3次元点群に対して共通領域を基に点群の位置合わせを行うことで相対位置姿勢を推定する。また、Zhang ら (Zhang and Singh, 2014) はこの位置合わせにおいて、平面やエッジの特徴量を活用している。一方、清水ら (清水, 黒田, 2014) は、点群そのままではなくクラスタリングした法

線をガウス球に投影し、支配的な法線（主平面）で位置合わせを行っている。また、カメラや RGB-D カメラを用いた SLAM による相対姿勢推定も提案されている (Engel et al., 2014)(Kerl et al., 2013)(Engel et al., 2018)。これらの手法は、初期姿勢に対する相対変化を推定するため、蓄積誤差を補正することが難しい。この蓄積誤差を補正する方法として、事前情報と時々刻々のセンサ情報とを対応付けする手法があり、特に事前環境地図を用いる手法が多く提案されている (Quddus et al., 2007)。また、人工環境での特徴を利用した手法も以下のように提案されている。S. Ramalingam ら (Ramalingam et al., 2010) は、街の 3 次元モデルと、全点球カメラの画像をマッチングを行う。このマッチングでは、空を見上げた時の空と建物の境界線 (skylines) を用いている。後藤ら (後藤他, 2017) は同様にモデルと全点球カメラの対応付けを提案しており、天井から床に至る線分および天井と壁、床と壁との線分など、人工物環境に多数存在する線分をマッチングの特徴量として用いて 6 自由度位置姿勢推定を行っている。Alberto Y. Hata ら (Hata et al., 2014) は自動車のための自己位置推定を提案しており、縁石の情報を含んだ地図と、センサで観測した縁石とのマッチングを行っている。このような環境地図や 3 次元モデルの使用は、性能が良いが適用可能な環境を限定する。また、高精度な GPS と慣性航法装置を利用した車両のピッチ角推定法も提案されている (Ryu et al., 2002)(Bae et al., 2001)。しかし GPS の使用も、同様に適用可能な環境を限定する。一方、李ら (李他, 2015) は、車載単眼カメラを用いた走行道路に対するピッチ角推定法を提案している。車両が道路平面上を走行するという点に注目し、前後フレーム間の並進ベクトルが走行道路平面に平行である拘束を用いて累積誤差のない推定を示している。しかしここで推定される姿勢角は道路に対する姿勢角でありワールド座標系での絶対値ではない。

本研究では、従来用いられる慣性センサと SLAM の統合に加え、鉛直に建てられた建造物の壁に対する相対姿勢をワールド座標系における絶対姿勢として観測することで、誤差の蓄積を適時補正する姿勢推定法を提案する。主に、時々刻々での推定精度を重視しており、ループクローズによる過去の軌跡の補正は本研究の趣旨と一致しない。なお、本手法は、一般的な建造物の壁がおおよそ鉛直に建てられていることを利用し、事前環境地図を必要としない。屋外での実機走行実験によって本手法の有用性を示す。

2. 建造物の壁に対する相対姿勢を用いた姿勢推定

本章では建造物の壁に対する相対姿勢を用いた姿勢推定について述べる。ロボットが静止している状態で IMU によって初期姿勢を求め、それに対して角速度センサを用いたデッドレコニングおよび SLAM で推定される相対姿勢変化を積算する。鉛直面を観測した場合は、それらを用いてロボット座標系での重力ベクトルを推定し蓄積誤差を補正する。なお、この推定姿勢はカルマンフィルタの観測値として統合される。

2.1 変数定義

2.1.1 座標系の定義

座標系を以下に定義する。

- ロボット座標系
ロボットに固定され、進行方向を X 軸の正とする右手直交座標系とする。各軸を X_r , Y_r , Z_r 軸とする。
- ワールド座標系
初期姿勢位置において原点がロボット座標系と一致し、重力方向を Z 軸の負とする右手直交座標系とする。各軸を X_w , Y_w , Z_w 軸とする。

2.1.2 拡張カルマンフィルタで用いる変数の定義

第 2.2 節および第 2.4 節で拡張カルマンフィルタを用いるため、表 1 に使用する変数の定義を示す。本論文内での拡張カルマンフィルタの記述ではこれらの変数を共通して用いる。

2.1.3 姿勢角の定義

ワールド座標系の X_w 軸, Y_w 軸, Z_w 軸まわりの姿勢角をそれぞれ ϕ , θ , ψ とする。また、姿勢角の定義域は $[-\pi, \pi]$ であり、数値的に不連続であることを考慮する必要があるが、具体的な処理の記述は省略する。

Table 1 Nomenclature.

| | |
|--------------|---|
| k | discrete time step |
| f, h | non-linear process and measurement model function |
| \mathbf{x} | state vector |
| \mathbf{z} | measurement vector |

2.2 IMU を用いた初期姿勢推定

ロボットが静止している状態での IMU の出力値を用いてワールド座標系におけるロボットの初期姿勢を推定する。また角速度センサのバイアス ω_{bias} も推定する。初期姿勢の推定には拡張カルマンフィルタを用い、カルマンフィルタの分散が収束するまでの時間、IMU を静止させておく必要がある。式 (1) ~ (4) でそれぞれ示される状態ベクトル、観測ベクトル、状態方程式、観測方程式を用いて、IMU の出力値を取得するたびに予測、観測を行う。ロボットは静止状態であるため、ここでは $\psi = 0$ で一定とする。座標変換行列を \mathbf{R} 、ワールド座標系での重力ベクトルを $\mathbf{G}_{\text{world}}$ とする。加速度の平均値を α_{ave} 、角速度の平均値を ω_{ave} とする。例えば $\alpha_{\text{ave}, X_r, k}$ は k ステップでの X_r 軸方向の平均加速度値を表す。

$$\mathbf{x}_k = \begin{pmatrix} \phi_k & \theta_k \end{pmatrix}^T \quad (1)$$

$$\mathbf{z}_k = \begin{pmatrix} \alpha_{\text{ave}, X_r, k} & \alpha_{\text{ave}, Y_r, k} & \alpha_{\text{ave}, Z_r, k} \end{pmatrix}^T \quad (2)$$

$$f(\mathbf{x}_k) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \phi_{k-1} \\ \theta_{k-1} \end{pmatrix} \quad (3)$$

$$h(\mathbf{x}_k) = \mathbf{R}_k \mathbf{G}_{\text{world}} = \mathbf{R}_k \begin{pmatrix} 0 \\ 0 \\ G_{\text{world}, Z_w} \end{pmatrix} = \begin{pmatrix} -G_{\text{world}, Z_w} \sin \theta \\ G_{\text{world}, Z_w} \sin \phi \cos \theta \\ G_{\text{world}, Z_w} \cos \phi \cos \theta \end{pmatrix} \quad (4)$$

$$\omega_{\text{bias}} = \omega_{\text{ave}} \quad (5)$$

2.3 壁面を用いた推定姿勢補正

2.3.1 主法線抽出

測距センサで得られる点群を用いて、各注目点の近傍局所点群に主成分分析 (Pauly et al., 2002) を適用することで法線ベクトルを算出する。近傍点群は、kd-tree (Bentley, 1975) を用いて指定半径以内の点を探索することで得られる。センサから得られる点群は、センサから遠くなるほど点の密度が粗くなるため、注目点とセンサとの距離が大きいくほど、探索半径を大きくする。

この法線群から、信頼性の高い鉛直面を持つ法線を以下の条件で抽出する。

- 注目点を持つ近傍点の数が十分多い (密度が高い)。
- 式 (6) で算出される角度 β が十分小さい。これは 1 ステップ前の推定重力ベクトル $\mathbf{G}'_{\text{robot}}$ をもとに、観測された法線 \mathbf{N} が鉛直面を持つかを判定するものである。

$$\beta = \left| \cos^{-1} \frac{\mathbf{N} \cdot \mathbf{G}'_{\text{robot}}}{\|\mathbf{N}\| \|\mathbf{G}'_{\text{robot}}\|} - \frac{\pi}{2} \right| \quad (6)$$

- 法線に垂直な平面と近傍点群の二乗誤差が十分小さい (平面度が高い)。

抽出された法線群でガウス球 (Horn, 1984) を生成し、球内の点群に対してユークリッド距離に基づくクラスタ分析を適用する。ガウス球とは、各点が保有する法線ベクトルの各成分をユークリッド空間内に再配置することで得られる点群であり、この操作は一般にガウス写像と呼ばれる。なお本手法では、計算処理に含まれる点群を増やして精度を高めるため、適当な法線を反転させガウス球をさらに半球のみに反映している。つまり、平行で向

かい合う平面は同じ法線ベクトルを持つようにする。クラスタリング終了後に、メンバが閾値より少ないクラスは外れ値として除去する。各クラスが持つ点群の重心を算出し、それらの位置ベクトルを主法線（支配的な法線）として用いる。

2.3.2 重力ベクトル推定

クラスタリングされた主法線（ガウス球内での点）を用いてロボット座標系における単位重力ベクトル $\mathbf{G}_{\text{robot}}$ を推定する。主法線の数に応じて以下のように算出する。ただし、以下のように外積などで算出されるベクトルが、本来の重力ベクトルと方向が逆になる場合もある。そのため、算出後に、1ステップ前の重力方向をもとに、算出したベクトルの向きを判定する必要がある。

- 主法線の数：3 以上

主法線をガウス球における点として扱い、この点群に対する主成分分析で得た法線を重力ベクトルとする。ただし、クラスが持つ点の数で重み付けを行う。

- 主法線の数：2

2本の主法線ベクトル $\mathbf{N}_1, \mathbf{N}_2$ の外積を重力方向ベクトルとする。図 1a に推定の様子を示す。

$$\mathbf{G}_{\text{robot}} = \mathbf{N}_1 \times \mathbf{N}_2 \tag{7}$$

- 主法線の数：1

ワールド座標系における絶対的な姿勢を得るには、平行でない鉛直面が2面以上必要であるが、1ステップ前の推定重力ベクトル $\mathbf{G}'_{\text{robot}}$ を用いて、式 (8) のように部分的に推定重力ベクトルを補正し算出する。観測された法線ベクトルを \mathbf{N} とする。図 1b に推定の様子を示す。

$$\mathbf{G}_{\text{robot}} = \frac{\mathbf{G}'_{\text{robot}} - (\mathbf{G}'_{\text{robot}} \cdot \mathbf{N})\mathbf{N}}{\|\mathbf{G}'_{\text{robot}} - (\mathbf{G}'_{\text{robot}} \cdot \mathbf{N})\mathbf{N}\|} \tag{8}$$

- 主法線の数：0

重力方向を推定することが出来ない。

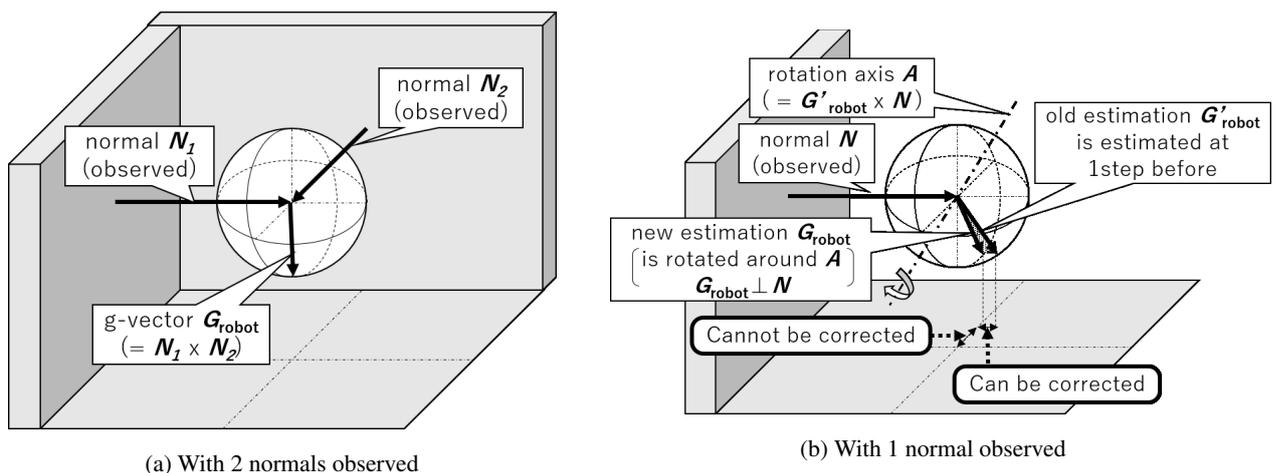


Fig. 1 In (a), the gravity vector $\mathbf{G}_{\text{robot}}$ is estimated by the cross product of the two observed normals $\mathbf{N}_1, \mathbf{N}_2$. $\mathbf{N}_1, \mathbf{N}_2$ are normals which are extracted and clustered, and they are not parallel. In (b), estimating the gravity vector $\mathbf{G}_{\text{robot}}$ is supposed to need two or more vectors which are not parallel to each other. The proposed method partially corrects the estimation of the gravity vector by using $\mathbf{G}'_{\text{robot}}$ which is estimated one step before.

2.3.3 推定姿勢補正

重力ベクトルの推定誤差が，推定姿勢の誤差であることを用いて補正する．なお計算は四元数 (quaternion) を用いて行う．ただし，第2.2節や第2.4節で記述されるカルマンフィルタでは，姿勢をロール，ピッチ，ヨーで扱っているため，四元数に変換する必要がある．補正後の姿勢を表す四元数 $\mathbf{q}_{\text{pose.wall}}$ の算出を以下に示す．1ステップ前の推定重力ベクトル $\mathbf{G}'_{\text{robot}}$ と，第2.3.2項で推定した推定重力ベクトル $\mathbf{G}_{\text{robot}}$ において，この2ベクトル間の回転を表す四元数 $\mathbf{q}_{\text{error}}$ は，

$$\begin{aligned} \mathbf{q}_{\text{error}} &= \begin{pmatrix} q_{\text{error},x} & q_{\text{error},y} & q_{\text{error},z} & q_{\text{error},w} \end{pmatrix} \\ &= \begin{pmatrix} C_{X_r} \sin \gamma/2 & C_{Y_r} \sin \gamma/2 & C_{Z_r} \sin \gamma/2 & \cos \gamma/2 \end{pmatrix} \end{aligned} \quad (9)$$

$$\gamma = \cos^{-1} \frac{\mathbf{G}'_{\text{robot}} \cdot \mathbf{G}_{\text{robot}}}{\|\mathbf{G}'_{\text{robot}}\| \|\mathbf{G}_{\text{robot}}\|} \quad (10)$$

$$\mathbf{C} = \begin{pmatrix} C_{X_r} & C_{Y_r} & C_{Z_r} \end{pmatrix}^T = \frac{\mathbf{G}'_{\text{robot}} \times \mathbf{G}_{\text{robot}}}{\|\mathbf{G}'_{\text{robot}}\| \|\mathbf{G}_{\text{robot}}\|} \quad (11)$$

推定重力ベクトル $\mathbf{G}'_{\text{robot}}$ に対応する推定姿勢を表す四元数を $\mathbf{q}'_{\text{pose}}$ としたとき，次のように補正される．

$$\mathbf{q}_{\text{pose.wall}} = \mathbf{q}'_{\text{pose}} \mathbf{q}_{\text{error}} \quad (12)$$

$\mathbf{q}_{\text{pose.wall}}$ および $\mathbf{q}'_{\text{pose}}$ はワールド座標系での姿勢であり， $\mathbf{q}_{\text{error}}$ はロボット座標系での誤差 (回転) である．

2.3.4 キャリブレーション

距離センサの取り付け誤差があった場合，それに合わせて点群を回転させる必要がある．ロボットが初期位置姿勢に静止している状態でキャリブレーションを行う．第2.2節で推定した初期姿勢を表す四元数 $\mathbf{q}_{\text{pose.ini}}$ に対する，第2.3.3項で推定した姿勢を表す四元数 $\mathbf{q}_{\text{pose.wall}}$ の誤差を取り付け誤差 $\mathbf{q}_{\text{misalignment}}$ とする．

$$\mathbf{q}_{\text{misalignment}} = \mathbf{q}_{\text{pose.wall}} \mathbf{q}_{\text{pose.ini}}^{-1} \quad (13)$$

初期姿勢推定後は，点群に対して回転 $\mathbf{q}_{\text{misalignment}}$ を適用させて上記の重力ベクトル推定を行う．

2.4 拡張カルマンフィルタによる統合

ここでは車輪型ロボットで人工環境を走行することを想定しており，各姿勢角度変化が急激なものではなく，カルマンフィルタで十分扱えると仮定する．IMUを用いたデッドレコニングで推定する姿勢を予測，SLAMで推定する姿勢を観測1，壁面に対する相対姿勢を観測2とし，拡張カルマンフィルタで統合する．

$$\mathbf{x}_k = \begin{pmatrix} \phi_k & \theta_k & \psi_k \end{pmatrix}^T \quad (14)$$

● 予測 (デッドレコニング)

ロボット座標系における角速度を，ワールド座標系へ座標変換しレート積分を行う．ただし，センサのバイアスを考慮している．

$$f(\mathbf{x}_{k-1}) = \begin{pmatrix} \phi_{k-1} \\ \theta_{k-1} \\ \psi_{k-1} \end{pmatrix} + \begin{pmatrix} 1 & \sin \phi_{k-1} \tan \theta_{k-1} & \cos \phi_{k-1} \tan \theta_{k-1} \\ 0 & \cos \phi_{k-1} & -\sin \phi_{k-1} \\ 0 & \sin \phi_{k-1} \sec \theta_{k-1} & \cos \phi_{k-1} \sec \theta_{k-1} \end{pmatrix} \begin{pmatrix} \omega_{X_r,k-1} - \omega_{\text{bias},X_r} \\ \omega_{Y_r,k-1} - \omega_{\text{bias},Y_r} \\ \omega_{Z_r,k-1} - \omega_{\text{bias},Z_r} \end{pmatrix} dt \quad (15)$$

● 観測 1 (SLAM)

SLAM によって得られる姿勢をそのまま観測するのではなく、1 ステップ前に SLAM で推定された姿勢との相対変化を用いることで、観測 2 を推定結果に反映しやすくする。

$$\mathbf{z}_k = \begin{pmatrix} \phi_{k-1} + (\phi_{\text{slam},k} - \phi_{\text{slam},k-1}) \\ \theta_{k-1} + (\theta_{\text{slam},k} - \theta_{\text{slam},k-1}) \\ \psi_{k-1} + (\psi_{\text{slam},k} - \psi_{\text{slam},k-1}) \end{pmatrix} \quad (16)$$

$$h(\mathbf{x}_k) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} \phi_k \\ \theta_k \\ \psi_k \end{pmatrix} \quad (17)$$

● 観測 2 (壁面観測)

上記 2 つのステップでは初期姿勢に対する相対姿勢を推定しているのに対し、ここではワールド座標系での絶対姿勢を直接観測することができる。式 (12) で算出される四元数 $\mathbf{q}_{\text{pose.wall}}$ をワールド座標系のロール、ピッチに変換し観測する。第 2.3.3 項で場合分けされるように、主法線の数に応じて共分散を変化させる。

$$\mathbf{z}_k = \begin{pmatrix} \tan^{-1} \frac{2(q_{\text{pose.wall},w}q_{\text{pose.wall},x} + q_{\text{pose.wall},y}q_{\text{pose.wall},z})}{q_{\text{pose.wall},w}^2 - q_{\text{pose.wall},x}^2 - q_{\text{pose.wall},y}^2 + q_{\text{pose.wall},z}^2} \\ \sin^{-1} 2(q_{\text{pose.wall},w}q_{\text{pose.wall},y} - q_{\text{pose.wall},x}q_{\text{pose.wall},z}) \end{pmatrix} \quad (18)$$

$$h(\mathbf{x}_k) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} \phi_k \\ \theta_k \\ \psi_k \end{pmatrix} \quad (19)$$

3. 評価実験

3.1 実験 (A)

3.1.1 実験 (A) 概要

起伏のあるコースで移動ロボットを走行させ、提案手法および比較手法で、時々刻々のロボットの自己姿勢を推定した。走行中の推定姿勢を評価することは難しいため、推定姿勢と並進速度を統合することで、走行中の推定姿勢誤差を、走行終了時の推定位置誤差に置き換えて評価した。つまり、同じ並進速度を用いた場合、姿勢の推定誤差が小さいほど、推定位置（軌跡）の誤差が小さくなると仮定した。

3.1.2 実験 (A) 環境

本実験での提案手法のシステム図を図 2 に示す。図中、Static は第 2.2 節の初期姿勢推定のシステム、Dynamic は走行開始後のシステムをそれぞれ表している。カルマンフィルタの観測で用いる SLAM として、LSD-SLAM(Engel et al., 2014) を用いた。LSD-SLAM とは単眼カメラ SLAM である。推定のレート of the speed and scale to be independent of the pose estimation is judged and selected. 図中、Integration では式 (4) で用いた座標変換行列 \mathbf{R} を用い、式 (20) のように座標変換を行い、姿勢と並進速度が統合される。 $\mathbf{V}_{\text{robot}}$ はロボット座標系での並進速度ベクトル、 $\mathbf{L}_{\text{world}}$ はワールド座標系でのロボットの推定位置ベクトルである。

$$\begin{aligned} \mathbf{L}_{\text{world},k} &= \mathbf{L}_{\text{world},k-1} + \mathbf{R}_k^{-1} \mathbf{V}_{\text{robot},k} dt \\ &= \mathbf{L}_{\text{world},k-1} + \mathbf{R}_k^T \mathbf{V}_{\text{robot},k} dt \\ &= \begin{pmatrix} L_{X_w,k-1} \\ L_{Y_w,k-1} \\ L_{Z_w,k-1} \end{pmatrix} + \mathbf{R}_k^T \begin{pmatrix} V_{\text{robot},X_r,k} \\ 0 \\ 0 \end{pmatrix} dt \end{aligned} \quad (20)$$

本実験では、統合される並進速度としてホイールオドメトリで得られる並進速度を用いた。

姿勢推定の比較手法として、ジャイロスコープによるデッドレコニングと、単独の LSD-SLAM を用いた。提案手法と同様に、これらの手法で姿勢をそれぞれ推定し、ホイールエンコーダの並進速度と統合した。なお、本研究の趣旨より、LSD-SLAM でのループクローズは行っていない。

図 3 に実験で使用される移動ロボットを示す。ロボットに搭載し、使用したセンサは、Velodyne HDL-32E, Xsens MTi30, RealSense D435, ホイールエンコーダである。RealSense D435 は RGB-D カメラであるが、LSD-SLAM のために画像のみを利用したため、深度情報は利用していない。評価に用いる真値として、走行開始時と走行終了時における、モーションキャプチャで得られる位置姿勢を用いた。本実験では Vicon Vero v1.3X を用いた。図 4 に、明治大学生田キャンパス内の実験環境の航空写真を示す。走行コースは、一周約 250m, 高低差約 3m であり、図 4 に示すように 3 周走行した。

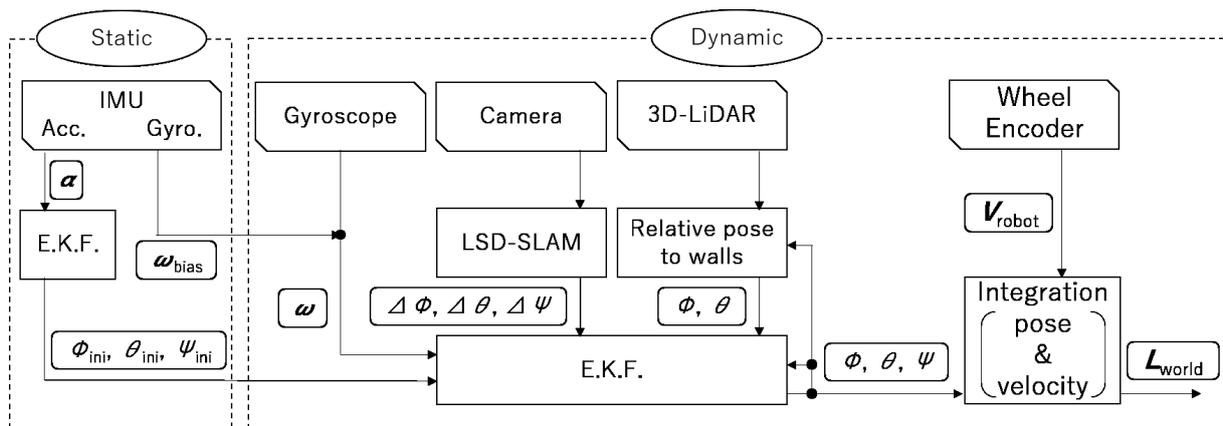


Fig. 2 A system configuration diagram of the proposed method for the experiment is shown here. “Static” part represents the system which runs when the robot has no move. “Dynamic” part represents the system after the robot starts driving. Estimating pose with vertical walls is referred to as “Relative pose to walls” in this figure, and the pose is merged through E.K.F. with other estimations. In “Integration” part, estimated pose(orientation) and linear velocity are integrated.

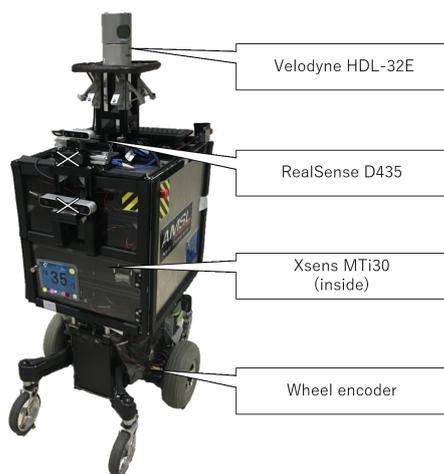


Fig. 3 The experimental mobile robot has 3D-LIDAR, camera, IMU and wheel encoders. RealSense D435 is RGBD camera, however this is just for LSD-SLAM and depth information is not used in the experiment.

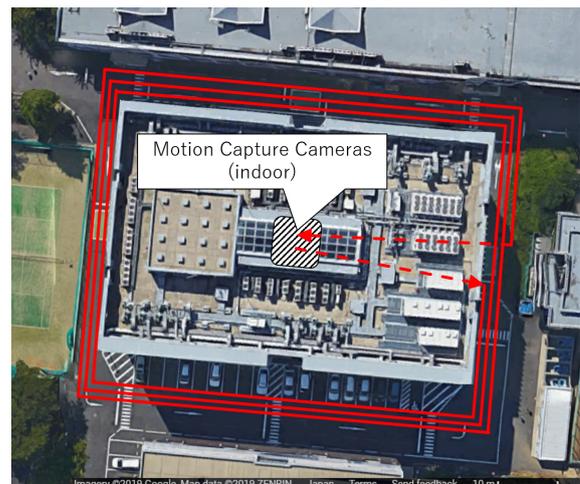


Fig. 4 An aerial shot of the experimental environment is shown here. Motion capture cameras locate on indoor area of a building. The robot starts driving at that area and comes back there. The course the robot drives has some slopes.

3-1-3 実験 (A) 結果

表 2 に、各手法での推定位置姿勢の誤差を示す。表中の誤差は、ワールド座標系の座標軸を基準とした位置および姿勢角の誤差である。また、Euc.dist. は、ユークリッド距離で表した位置推定誤差である。ユークリッド距離で表した位置推定誤差に関して、比較手法に比べて、提案手法の値が小さいことから、走行中の姿勢推定の誤差も提案手法の方が小さいと言える。図 5 に、各手法で推定されたロボットの軌跡を示す。この図より、同じコースを 3 周していることをふまえると、提案手法の推定軌跡の誤差がより小さいことが視覚的にも分かる。特に、 Z_w 軸（鉛直）方向の並進誤差が小さく抑えられており、壁面を用いた補正による結果だと考察する。第 2-3-2 項で記述したように、環境によって主法線の数が異なり、処理も異なる。表 3 に、この実験コースでの走行における、主法線の数に応じた壁情報での補正回数の割合を示す。表 4 に、同様の実験環境でさらに実験を繰り返した際の、提案手法による推定誤差の平均値および分散を示す。ただし、追加で行った実験では 1 周のみの走行であり、それを 5 回行った。

Table 2 Errors of position and pose estimations.

| error in... | X_w [m] | Y_w [m] | Z_w [m] | Euc.dist.[m] | ϕ [deg] | θ [deg] | ψ [deg] |
|-----------------|-----------|-----------|-----------|--------------|--------------|----------------|--------------|
| proposed method | +1.8843 | -0.6136 | +1.9233 | 2.762 | -2.069 | -0.095 | -0.300 |
| LSD-SLAM | +4.8471 | -2.3376 | +9.0677 | 10.544 | +6.922 | -8.721 | +18.257 |
| Gyrodometry | +2.0761 | -0.2382 | -2.6726 | 3.393 | -2.984 | +6.970 | -0.963 |

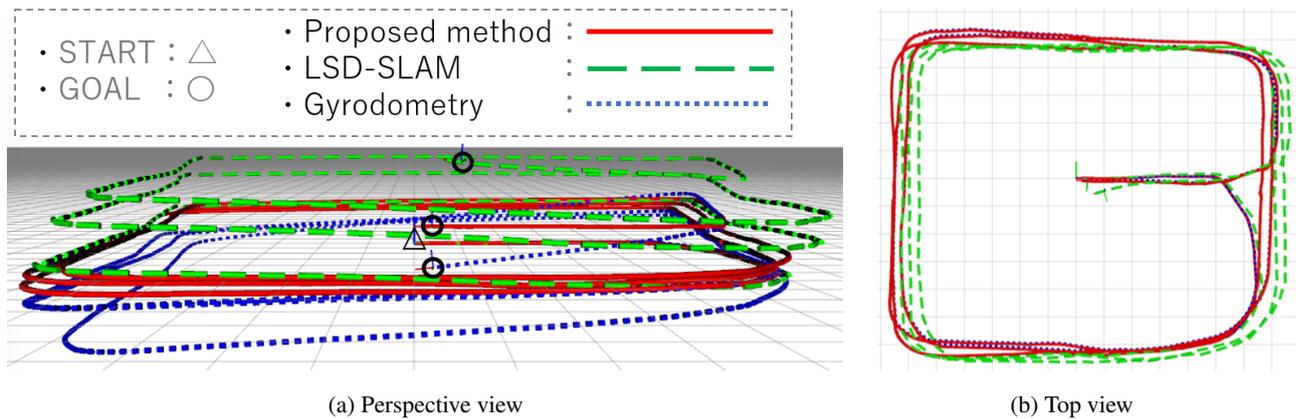


Fig. 5 Estimated trajectories of the robot are shown here. It is visually found that trajectories estimated by Gyrodometry and LSD-SLAM respectively have larger translational errors in Z_w axis.

Table 3 Ratio of times of each correcting type to number of scans.

| n : number of dominative normals | $n \geq 3$ | $n = 2$ | $n = 1$ | $n = 0$ |
|------------------------------------|------------|---------|---------|---------|
| ratio[%] | 0.09 | 39.06 | 60.84 | 0 |

Table 4 Average and variance of the proposed method in 1-round experiments.

| | X_w [m] | Y_w [m] | Z_w [m] | Euc.dist.[m] | ϕ [deg] | θ [deg] | ψ [deg] |
|------|-----------|-----------|-----------|--------------|--------------|----------------|--------------|
| ave. | 0.5119 | 0.4260 | -0.0748 | 0.8153 | 0.018 | 0.006 | 3.032 |
| var. | 0.1817 | 0.1967 | 0.0305 | 0.1030 | 0.059 | 0.120 | 5.034 |

3.2 実験 (B)

3.2.1 実験 (B) 概要

鉛直でない平面が提案手法に与える影響を、簡易的な実験によって検証した。鉛直面で囲まれた屋内空間に、鉛直でない平面を持つ障害物を設置し、第 2.3 節で記述したように鉛直面を観測し姿勢を推定した。ただし、ロボットは静止させ、IMU を使ったデッドレコニングおよび SLAM は行っていない。また、第 2.3.4 項のキャリブレーションは行っていない。

3.2.2 実験 (B) 環境

実験 (A) と同じロボットを用いて実験を行った。障害物として、表 5 のような掲示用のボードとアルミ板を使用し、傾斜角や障害物の種類および数を変えて比較した。図 6 に実験の様子、図 7 に実験環境で取得された点群をそれぞれ示す。実験環境が、屋内であり十分整備されているため、ロボットの姿勢角の真値は $\phi_{\text{true}} = 0$, $\theta_{\text{true}} = 0$ として評価に用いた。

3.2.3 実験 (B) 結果

表 6 に実験 (B) の結果を示す。表内の誤差は、1 分間の平均である。また、実験結果の様子为例として、実験 no.3 の 3 次元点群および法線群を図 8 に示す。なお図中の extracted normal は、第 2.3.1 項で設定される条件を満たし、信頼性が高いと判定された法線、clustered normal は主法線を表す。障害物の傾きが大きくなるほど、推定姿勢角の誤差は大きくなる。ただし、式 (6) の β が閾値を超えた場合、実験 no.4 のように障害物の影響がなくなる。実験 no.4 の様子を図 9 に示す。また、障害物が持つ平面の面積が大きいほど、推定姿勢角の誤差は大きくなる。これは第 2.3.2 項の通り、観測された法線の数が多い場合、クラスタが持つメンバの数で重み付けを行っていることに由来していると考えられる。ただし、メンバの数が閾値を下回った場合外れ値とするため、実験 no.5 のように、障害物の影響がなくなる。実験 no.5 の様子を図 10 に示す。信頼性の高い法線であるかの判定や、クラスタリングの外れ値であるかの判定の基準はパラメータで調節している。判定基準を厳しくすれば、鉛直面の誤認識を防げるが、本来の目的である補正がかかりづらくなってしまふ。想定される環境に応じて、適当に設定する必要がある。

Table 5 Detail of obstacles.

| name | dimention | description |
|-------------|------------------|------------------|
| small plane | 400 mm × 600 mm | aluminum board |
| large plane | 1530 mm × 900 mm | bulletelin board |

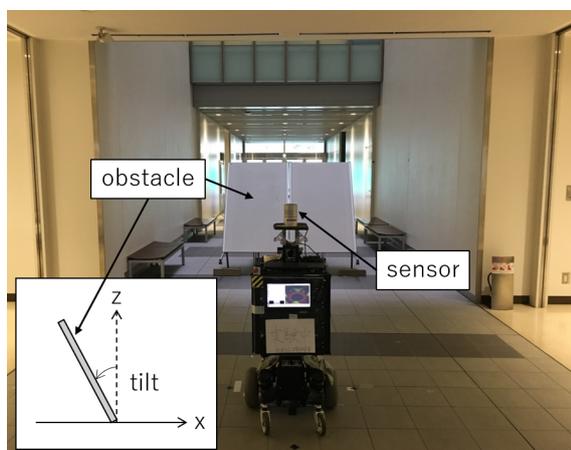


Fig. 6 The Environment of the experiment(B).

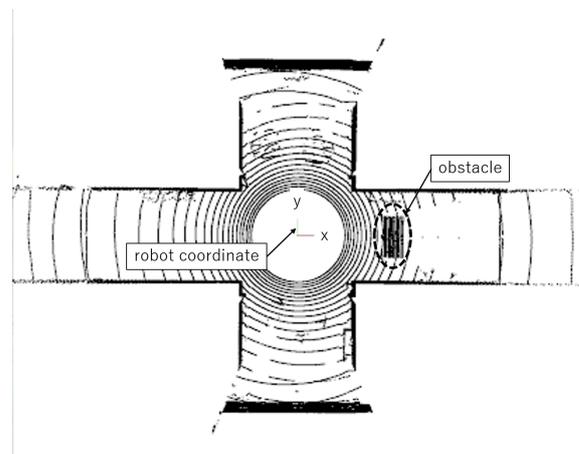


Fig. 7 Point cloud of the experimental environment(B).

Table 6 Errors of pose estimations with obstacles which are not vertical planes.

| no. | obstacle type | tilt[deg] | roll error[deg] | pitch error[deg] | recital |
|-----|---------------|-----------|-----------------|------------------|------------------------|
| 1 | no obstacle | - | +0.103 | -0.831 | - |
| 2 | large plane×1 | 15 | +1.24 | +1.57 | - |
| 3 | large plane×1 | 30 | +1.89 | +3.01 | - |
| 4 | large plane×1 | 45 | +0.104 | -0.831 | out of the angle range |
| 5 | small plane×1 | 30 | +0.113 | -0.832 | outlier |
| 6 | large plane×2 | 30 | +3.96 | +7.38 | - |

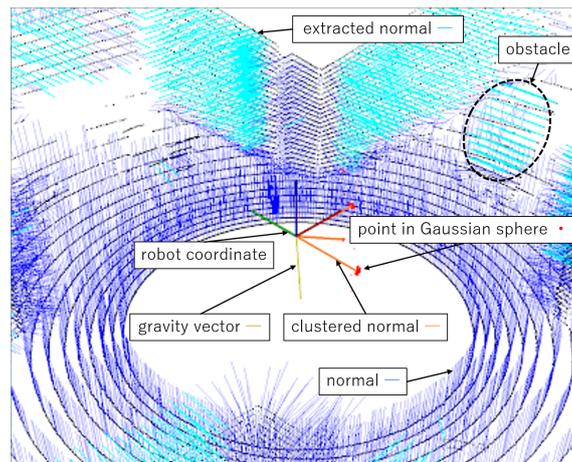


Fig. 8 Point and normal cloud in the experiment no.3 are shown here. Extracted normals are picked out from the original normals, with conditions for judging whether a normal has a vertical plane. These extracted normals are projected to a Gaussian sphere. And the points in the Gaussian sphere are clustered.

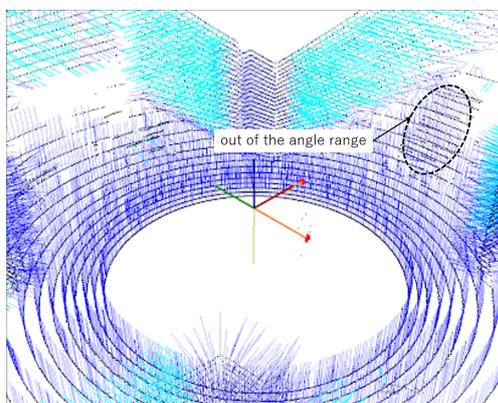


Fig. 9 Point and normal cloud of the experiment no.4 are shown here. There is no influence for the pose estimation when experimental obstacles are tilted more than the threshold which the proposed method has.

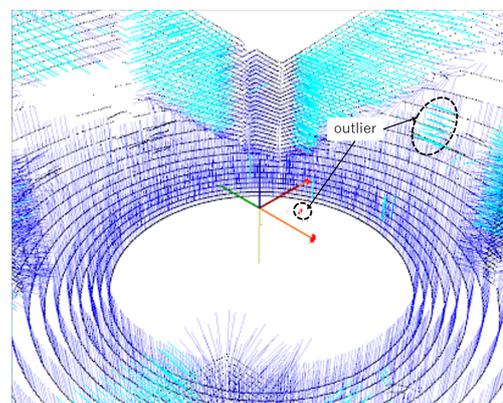


Fig. 10 Point and normal cloud of the experiment no.5 are shown here. There is no influence for the pose estimation when experimental obstacles are small enough to be recognized as outliers in the clustering step.

4. 結 言

従来の慣性センサと SLAM による移動ロボットの姿勢推定に加え、鉛直に建てられている建造物の壁に対する相対姿勢を利用する姿勢推定法を提案した。実験 (A) の結果より、鉛直面を用いることで走行中における姿勢推定の蓄積誤差を小さく抑えるという本提案手法の有用性が示された。また、実験 (B) の結果より、鉛直でない平面に対する処理の有効性も示された。ただし、想定される環境に応じて判定基準を適切に設定する必要がある。

謝 辞

本研究の一部は、国立研究開発法人新エネルギー・産業技術総合開発機構（NEDO）の、次世代人工知能・ロボット中核技術開発事業による支援を受けた。ここに篤く御礼申し上げる。

文 献

- Bae, H. S., Ryu, J. and Gerdes, J. C., Road grade and vehicle parameter estimation for longitudinal control using GPS, Proceedings of IEEE Conference on Intelligent Transportation Systems (2001), pp.166–171.
- Bentley, J.L., Multidimensional binary search trees used for associative searching, Communications of the ACM, Vol.18, No.9 (1975), pp.509–517.
- Biber, P. and Straßer, W., The normal distributions transform: a new approach to laser scan matching, Proceedings of the IEEE International Conference on Intelligent Robots and Systems, Vol.3 (2003), pp.2743–2748.
- Engel, J., Koltun, V. and Cremers, D., Direct sparse odometry, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.40, No.3 (2018), pp.611–625.
- Engel, J., Stueckler, J. and Cremers, D., LSD-SLAM: large-scale direct monocular SLAM, European Conference on Computer Vision (2014), pp.834–849.
- 後藤 翼, Pathak, S., 池 勇勳, 藤井 浩光, 山下 淳, 浅間 一, 人工物環境における全天球カメラの位置姿勢推定のための直線特徴に基づく 3D-2D マッチング, 精密工学会誌, Vol.83, No.12 (2017), pp.1209–1215.
- Hata, A. Y., Osorio, F. S. and Wolf, D. F., Robust curb detection and vehicle localization in urban environments, IEEE Intelligent Vehicles Symposium Proceedings (2014), pp.1257–1262.
- Horn, B. K. P., Extended gaussian images, Proceedings of the IEEE, Vol.72, No.12 (1984), pp.1671–1686.
- Kerl, C., Sturm, J. and Cremers, D., Dense visual SLAM for RGB-D cameras, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (2013), pp.2100–2106.
- Kwon, S., Kim, S. and Yu, J., Tilting-type balancing mobile robot platform for enhancing lateral stability, IEEE/ASME transactions on mechatronics, Vol.20, No.3 (2015), pp.1470–1481.
- 李 博, 張 曉林, 佐藤 誠, 車間距離計測のための車載単眼カメラを用いたピッチ角推定, 映像情報メディア学会誌 Vol.69, No.4 (2015), pp.169–176.
- Magnusson, M., Lilienthal, A. and Duckett, T., Scan registration for autonomous mining vehicles using 3D-NDT, Journal of Field Robotics, Vol.24, No.10 (2007), pp.803–827.
- Pauly, M., Gross, M. and Kobbelt, L.P., Efficient simplification of point-sampled surfaces, Proceedings of the conference on Visualization (2002), pp.163–170.
- Quddus, M. A., Ochieng, W. Y. and Noland, R. B., Current map-matching algorithms for transport applications: state-of-the art and future research directions, Transportation Research Part C: Emerging Technologies, Vol.15, No.5 (2007), pp.312–328.
- Ramalingam, S., Bouaziz, S., Sturm, P. and Brand, M., SKYLINE2GPS: localization in urban canyons using omnisky-lines, IEEE/RSJ International Conference on Intelligent Robots and Systems (2010), pp.3816–3823.
- Rusinkiewicz, S. and Levoy, M., Efficient variants of the ICP algorithm, Proceedings Third International Conference on 3-D Digital Imaging and Modeling (2001), pp.145–152.
- Ryu, J., Rossetter, E. J. and Gerdes, J. C., Vehicle sideslip and roll parameter estimation using GPS, Proceedings of the Symposium on Advanced Vehicle Control (2002), pp.373–380.
- 清水尚吾, 黒田洋司, 主平面を用いた点群の高速位置合わせ, 第 19 回ロボティクスシンポジウム講演予稿集 (2014), pp.453–458.
- Stumberg, L.von, Usenko, V. and Cremers, D., Direct sparse visual-inertial odometry using dynamic marginalization, in International Conference on Robotics and Automation (2018), pp.2510–2517.
- Thrun, S., Burgard, W. and Fox, D., Probabilistic robotics (2005), pp.309–336, The MIT Press.
- Zhang, J. and Singh, S., LOAM: lidar odometry and mapping in real-time, in Robotics: Science and Systems Conference (2014), pp.161–195.

References

- Bae, H. S., Ryu, J. and Gerdes, J. C., Road grade and vehicle parameter estimation for longitudinal control using GPS, Proceedings of IEEE Conference on Intelligent Transportation Systems (2001), pp.166–171.
- Bentley, J.L., Multidimensional binary search trees used for associative searching, Communications of the ACM, Vol.18, No.9 (1975), pp.509–517.
- Biber, P. and Straßer, W., The normal distributions transform: a new approach to laser scan matching, Proceedings of the IEEE International Conference on Intelligent Robots and Systems, Vol.3 (2003), pp.2743–2748.
- Engel, J., Koltun, V. and Cremers, D., Direct sparse odometry, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol.40, No.3 (2018), pp.611–625.
- Engel, J., Stueckler, J. and Cremers, D., LSD-SLAM: large-scale direct monocular SLAM, European Conference on Computer Vision (2014), pp.834–849.
- Goto, T., Pathak, S., Ji, Y., Fujii, H., Yamashita, A. and Asawa, H., 3D-2D matching of line features for spherical camera localization in man-made environment, Journal of the Japan Society for Precision Engineering, Vol.83, No.12 (2017), pp.1209–1215 (in Japanese).
- Hata, A. Y., Osorio, F. S. and Wolf, D. F., Robust curb detection and vehicle localization in urban environments, IEEE Intelligent Vehicles Symposium Proceedings (2014), pp.1257–1262.
- Horn, B. K. P., Extended gaussian images, Proceedings of the IEEE, Vol.72, No.12 (1984), pp.1671–1686.
- Kerl, C., Sturm, J. and Cremers, D., Dense visual SLAM for RGB-D cameras, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (2013), pp.2100–2106.
- Kwon, S., Kim, S. and Yu, J., Tilting-type balancing mobile robot platform for enhancing lateral stability, IEEE/ASME transactions on mechatronics, Vol.20, No.3 (2015), pp.1470–1481.
- Li, B., Zhang, X. and Sato, M., Pitch angle estimation using a vehicle mounted monocular camera for vehicle target range measurement, The journal of the Institute of Image Information and Television Engineers, Vol.69, No.4 (2015), pp.169–176 (in Japanese).
- Magnusson, M., Lilienthal, A. and Duckett, T., Scan registration for autonomous mining vehicles using 3D-NDT, Journal of Field Robotics, Vol.24, No.10 (2007), pp.803–827.
- Pauly, M., Gross, M. and Kobbelt, L.P., Efficient simplification of point-sampled surfaces, Proceedings of the conference on Visualization (2002), pp.163–170.
- Quddus, M. A., Ochieng, W. Y. and Noland, R. B., Current map-matching algorithms for transport applications: state-of-the art and future research directions, Transportation Research Part C: Emerging Technologies, Vol.15, No.5 (2007), pp.312–328.
- Ramalingam, S., Bouaziz, S., Sturm, P. and Brand, M., SKYLINE2GPS: localization in urban canyons using omni-skylines, IEEE/RSJ International Conference on Intelligent Robots and Systems (2010), pp.3816–3823.
- Rusinkiewicz, S. and Levoy, M., Efficient variants of the ICP algorithm, Proceedings Third International Conference on 3-D Digital Imaging and Modeling (2001), pp.145–152.
- Ryu, J., Rossetter, E. J. and Gerdes, J. C., Vehicle sideslip and roll parameter estimation using GPS, Proceedings of the Symposium on Advanced Vehicle Control (2002), pp.373–380.
- Shimizu, S. and Kuroda, Y., High-speed registration of point clouds by using dominant planes, Proceedings of the 19th Robotics Symposia (2014), pp.453–458 (in Japanese).
- Stumberg, L.von, Usenko, V. and Cremers, D., Direct sparse visual-inertial odometry using dynamic marginalization, in International Conference on Robotics and Automation (2018), pp.2510–2517.
- Thrun, S., Burgard, W. and Fox, D., Probabilistic robotics (2005), pp.309–336, The MIT Press.
- Zhang, J. and Singh, S., LOAM: lidar odometry and mapping in real-time, in Robotics: Science and Systems Conference (2014), pp.161–195.