

単眼カメラと汎用センサ統合による都心部の高精度推測航法

武山 洪二郎^{1,2,a)} 町田 貴史¹ 小島 祥子¹ 久保 信明²

受付日 2017年6月12日, 採録日 2017年12月8日

概要: 本研究では単眼カメラと汎用センサを統合した高精度推測航法を提案する。近年、自動車の運転支援システムではシームレスかつ高精度な自車位置情報が求められている。RTK-GPSなどの衛星測位は上空が遮蔽されやすい都心部において使用可能な場所が限られるため、その間の区間をつなぐ推測航法の精度が重要となる。近年、高精度・低コストを実現可能な推測航法として、単眼カメラ画像から自車の軌跡推定を行う Visual Odometry (VO) が注目されているが、長区間の走行では方位誤差の蓄積が課題となる。そこで本研究では VO の課題である方位の蓄積誤差に対し、GPS のドップラーシフトを用いた方位補正を行うことで精度向上を行った。提案手法では都心部における衛星数減少への対策として、GPS と IMU の時系列データを密に統合することで、衛星数が少ない環境における方位補正の頻度を向上した。都心部にて評価を行った結果、提案手法では衛星数が少ない環境における方位補正頻度の改善を確認し、これにともない VO の軌跡誤差は従来に比べ 3 割以上低減した。

キーワード: 推測航法, ビジュアルオドメトリ, 単眼カメラ, マルチセンサ, 車両方位, 都心部

Precise Dead-reckoning in Urban Environment through Tightly Coupled Integration of Mono-camera, IMU and GPS

KOJIRO TAKEYAMA^{1,2,a)} TAKASHI MACHIDA¹ YOSHIKO KOJIMA¹ NOBUAKI KUBO²

Received: June 12, 2017, Accepted: December 8, 2017

Abstract: In this paper, a method of accurate dead-reckoning in urban area through the integration of mono-camera, IMU, and GPS is proposed. Recently, the robust and accurate vehicle position information has become an essential task for the driver's assistant systems. Especially the dead-reckoning plays an important role for the continuous positioning in the areas GPS positioning is limited such as urban canyons. Visual-Odometry (VO) using mono-camera is a method of dead-reckoning which has a potential to achieve low cost and high performance, but has an accumulated heading error along the traveled distance. This study presents a method of heading estimation using the Doppler shift of GPS which corrects the accumulated heading error of VO. Moreover, in the proposed method, the time-series data of Doppler shift of GPS and IMU are tightly integrated and that contributes to the improvement of availability of heading correction in the satellite signal blocked area such as urban canyons. As a result of evaluation in the urban city, the error of dead-reckoning is reduced by about 30% owing to the improvement of availability of heading correction in the urban environment.

Keywords: dead-reckoning, visual odometry, mono-camera, multi-sensor integration, heading estimation, urban environment

¹ 株式会社豊田中央研究所
Toyota Central Research & Development Laboratories Inc.,
Nagakute, Aichi 480-1192, Japan

² 東京海洋大学
Tokyo University of Marine Science and Technology, Koto,
Tokyo 135-8533, Japan

^{a)} takeyama@mosk.tytlabs.co.jp

1. はじめに

近年、自動車の運転支援システムは目覚ましい発展を見せており、衝突回避、協調運転、操作支援など様々な機能により走行環境の安全性・利便性が向上している。さらに最近では高精度な車両位置情報を活用したアプリケーション

ンが提案されており、死角からの他車との衝突回避、レーンレベルでのナビゲーション、あるいは自動地図生成 [1] などの高度な機能実現が期待されている。一般的なカーナビで求められる位置精度は数 m 程度であるのに対し、これらのアプリケーションではおおむね 1 m 程度またはそれ以下の位置精度が求められるため、高精度な車両位置情報を得るための測位技術の開発が重要となる。現状、衛星の搬送波位相を利用した RTK-GPS [2] では数 cm～数十 cm 程度の測位精度を得られるが、都心部では建物による衛星信号の遮蔽や反射が発生するため、高精度測位が可能な場所が限定される。このため、高精度測位点間の区間をつなぐ推測航法の精度が非常に重要となる (図 1)。

推測航法は任意の位置からの相対的な自車位置 (走行軌跡) を計るための手段であり、ジャイロの方位変化と車輪速から算出した速度ベクトルを積算する簡易的な方法から、LIDAR (Laser Imaging Detection and Ranging) で計測した周辺物との相対位置関係から自車の軌跡を算出する高度な方法 [3] まで精度/コストが異なる多様なアプローチがある。近年では、比較的安価で高い軌跡精度を狙える方法として、単眼カメラ画像を用いた Visual Odometry [4], [5] (以下、VO) の研究が精力的に行われている。VO は連続するカメラ画像内に写る周辺物体の動きから相対的に自車の動きを推定する手法である。周辺に建物などの立体物がある環境であれば精度良く軌跡推定を行うことができ、近年では標準装備になりつつある車載カメラを利用するため LIDAR よりも大幅にコストを抑えられるメリットがある。一方、VO は時間的に連続して得られる画像情報から自車位置/姿勢を逐次的に更新していく手法であるため、走行区間が長くなるにつれ自車の姿勢、とりわけ進行方位の誤差が蓄積することによって走行軌跡の誤差が拡大していくことが 1 つの課題となる。そこで本研究では、長区間における VO の軌跡誤差低減を目的とする。本研究では軌跡誤差増加の主要因となる方位の蓄積誤差を随時補正することで、長区間においても高精度な VO の実現を目指す。




図 1 推測航法利用イメージ
Fig. 1 Role of Dead-reckoning.

2. 従来手法と課題

VO の課題である方位蓄積誤差に対し、これまで様々な方位補正手法が提案されている。Heng ら [6] は磁力方位計による方位補正を提案し、周辺に人工物がない場所では方位蓄積誤差の低減効果が得られたが、都心部のように鉄道や高架橋などの大規模な金属製構造物がある環境では干渉による誤差が課題となる。また、Rehder ら [7] は GPS の測位点から得た軌跡と VO の軌跡が整合するよう方位補正を行い、河川沿いの開けた環境で方位誤差低減を確認したが、都心部では GPS 測位点の頻度・精度はともに大きく劣化するため方位補正に用いることは困難となる。また、目黒ら [8] は GPS のドップラーシフトから得られる自車の速度ベクトルから絶対方位を算出し車両の方位補正に用いたが、やはり都心部では衛星信号の遮蔽・反射にともない方位精度が劣化するため実用は困難である。Alonso ら [9] は GPS に加えてデジタル道路地図情報を用いて方位補正を行うことで都心部における VO の精度向上を実現したが、提案手法では高精度な広域道路地図を整備する必要があり、現状ではコスト面で課題があるといえる。

これに対し本研究では、汎用的な車載センサのみの利用で都市環境でもロバストな方位補正手法を提案し、これを VO と組み合わせることで軌跡推定精度を向上した。

3. 提案手法

図 2 に提案手法の概要を示す。提案手法では VO による推測航法を基本とし、GPS のドップラーシフトを用いた方位推定結果を組み合わせることで方位誤差が蓄積しにくい推測航法を実現する。一般的に GPS のドップラーシフトを用いた方位推定は同時に 4 個以上の衛星を観測する必要があるため、都心部では方位推定の頻度が著しく低下するが、提案手法ではドップラーシフトと IMU の時系列データを密に統合することで衛星数が 4 未満の場合でも方位推

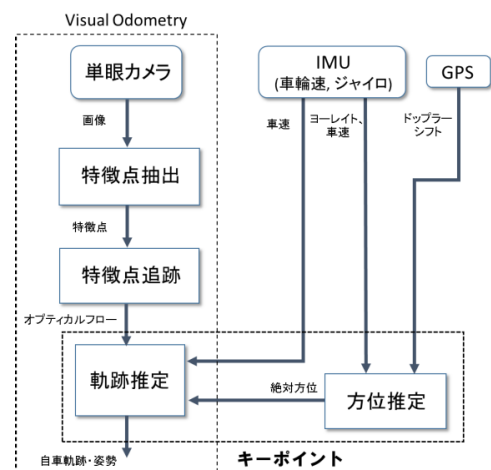


図 2 提案手法の流れ
Fig. 2 Overview of the proposed method.

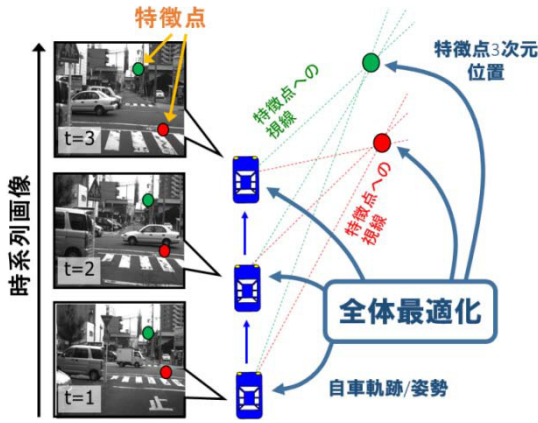


図3 バンドルアジャスト方式概要

Fig. 3 Visual odometry using bundle adjustment.

定を可能にする枠組みを特長とする。また、本研究では衛星から得た方位をVOの最適化問題に組み込み入れて解くことで、VOの方位誤差を低減し軌跡精度向上を実現した。

本章では始めに提案手法の基礎となる Visual Odometry の基本原理について簡単に説明した後、GPSを用いた方位推定手法、およびVOとの統合方法について述べる。

3.1 Visual Odometry

Visual Odometry (VO) は画像中の静止物体の動きから相対的に自転車運動を推定する手法である。ここではその基本原理について簡単に説明する。VOは連続する2時刻間の画像から自転車運動を推定する方法 [3], [4] が簡易的な方法として知られているが、ここでは複数時刻の画像から自転車運動を推定するバンドルアジャスト方式 [10] を用いる。バンドルアジャスト方式では、まず画像中の特徴点を複数時刻にわたり追跡する。次に各時刻における自転車から特徴点への視線を引き、これらが1点に交わるような自転車の軌跡・姿勢と特徴点位置を算出する (図3)。2時刻画像を用いる逐次推定方式に比べ計算量は増える傾向にあるが、複数時刻の観測値を同時に最適化するため蓄積誤差が増加しにくい特長がある。

以下にバンドルアジャスト方式による軌跡・姿勢推定の方法を示す。一般的に画像中の特徴点位置、自転車の位置 (軌跡)、自転車の姿勢、実空間中の特徴点位置の関係式 (観測方程式) は以下のように表される。

$$\mathbf{X}'_{t,m} = \mathbf{K}\mathbf{R}_t[I | -\mathbf{x}_t]\mathbf{X}_m \quad (1)$$

ここで、 $\mathbf{X}'_{t,m}$ は画像中の特徴点位置 (観測値)、 \mathbf{K} はカメラのキャリブレーション行列 (既知)、 \mathbf{R}_t は自転車の姿勢 (ピッチ, ヨー, ロール) を要素とした3次元回転行列 (未知数)、 \mathbf{x}_t は3次元自転車位置 (未知数)、 \mathbf{X}_m は実空間中の特徴点の3次元位置 (未知数) を示す。 t, m はそれぞれ時刻インデックス, 特徴点インデックスを示す。

通常、観測方程式は十分な数が得られるため、最小二乗法により式 (2) に示すコスト関数を最小化する解を算出




図4 提案手法の基本的アイデア

Fig. 4 Concept of the proposed method.

する。式 (2) は非線形であるため、Levenberg-Marquardt 法 [11] などの収束演算を用いて解くことができる。

$$E_{cam}(\mathbf{R}_t, \mathbf{x}_t, \mathbf{X}_m) = \sum_{t=0}^M \sum_{m=0}^N (\mathbf{X}'_{t,m} - \mathbf{K}\mathbf{R}_t[I | -\mathbf{x}_t]\mathbf{X}_m)^2 \quad (2)$$

(M, N はそれぞれ推定に用いる時系列データ数, 特徴点数)

3.2 衛星ドップラーシフトを用いた方位推定

VOは短い区間においては非常に良い軌跡精度が得られる一方、長い区間においては走行距離とともに方位誤差が累積していくため、軌跡誤差も増加する傾向にある。そこで本研究では衛星のドップラーシフトを用いた方位補正を提案した。

通常、4機以上の衛星のドップラーシフトを用いることで車両の進行方位を推定できる [12] が、都心部では信号の遮蔽により衛星数の不足が生じ方位推定の頻度が大幅に減少することがある。そこで本研究では衛星のドップラーシフトとIMU (ジャイロ, 車輪速) を統合することで衛星不足時においても方位推定を可能とする手法を構築し、都心部における推測航法精度を向上した。

図4に提案手法による方位推定の基本コンセプトを示す。提案手法は衛星の時系列データを集めて利用することで衛星数不足を補うことを特徴とする。衛星の時系列データを単純に観測方程式として連立した場合、各時刻における自転車の位置・姿勢が新たな未知数となるため、時系列データ利用の恩恵は得られない。これに対し、本研究ではIMUから得られる自転車位置・姿勢の変化量を拘束条件として利用することで未知数の増加を抑え、見かけ上の衛星数のみを増加することができた。その結果、1時刻あたりの衛星数が最低1機の場合においても方位推定が可能となった。

以下では提案手法の詳細について述べる。式 (3) に衛星のドップラーシフトと自転車の3次元速度ベクトルの関係式を示す。

$$V_{s_i} = \mathbf{G}_i \cdot \mathbf{V} - c\tau \quad (3)$$

$$\mathbf{G}_i = \frac{\mathbf{x}'_i - \mathbf{x}}{|\mathbf{x}'_i - \mathbf{x}|}, \quad V_{s_i} = \frac{D_i}{f_1}c - \mathbf{G}_i \cdot \mathbf{v}'_i,$$

$$(i = 1, \dots, N)$$

i は衛星のインデックス, N は 1 時刻あたりに観測可能な衛星数, V_{s_i} は自車と衛星の相対速さ (m/s), \mathbf{G}_i は自車-衛星間の視線方向単位ベクトル (無次元), \mathbf{V} は自車の 3 次元速度ベクトル (m/s), τ はクロックドリフトと呼ばれる衛星受信機の時計誤差変化率 (無次元), c は光速 (m/s) を示す. ここで, \mathbf{G}_i は衛星位置 \mathbf{x}'_i と自車位置 \mathbf{x} を用いて算出でき, V_{s_i} は衛星のドップラーシフト D_i (Hz), 光速 c , 衛星信号の搬送波周波数 f_1 (Hz), 単位ベクトル \mathbf{G}_i , 衛星の 3 次元速度ベクトル \mathbf{v}'_i (m/s) を用いて表すことができる. 式 (3) 中, 未知数は \mathbf{V} (3 次元自車速度ベクトル) と τ (クロックドリフト) の 4 つであり, 他の変数はすべて既知である. 式 (3) は観測可能な衛星と同数だけ連立できるため, 4 つの未知数を解くためには最低 4 機の衛星が必要となる.

提案手法では観測値として利用可能な衛星を増加するため, まず式 (3) の観測方程式を時系列方向に拡張する (式 (4)).

$$V_{s_{t,i}} = \mathbf{G}_{t,i} \cdot \mathbf{V}_t - c\tau_t \quad (4)$$

$$(t = 0, \dots, M; i = 1, \dots, N_t)$$

t は時刻インデックス, N_t は時刻 t における衛星数を示す. 時系列データを用いることで, 連立できる観測方程式の数は時系列方向のデータ長に比例して増加するが, 時刻インデックスを持った未知数 \mathbf{V}_t , τ_t も同様に増加するため, 式 (4) の状態では解を得るために必要な衛星数は変わらない. そこで提案手法ではさらに IMU を用いて時系列の未知数に対し拘束条件を加えることで未知数の数を低減する.

まず, 式 (4) 中の 3 次元自車速度ベクトル \mathbf{V}_t を以下のように車速と方向に分解して表す.

$$\mathbf{V}_t = [Vx_t \quad Vy_t \quad Vz_t]$$

$$= |\mathbf{V}_t| [\cos \theta_t \quad \sin \theta_t \quad \sin \phi_t] \quad (5)$$

$[Vx_t \quad Vy_t \quad Vz_t]$ は平面座標系における自車速度ベクトルの 3 成分, $|\mathbf{V}_t|$ は自車速度ベクトルの大きさ, θ_t , ϕ_t はそれぞれ自車速度ベクトルの向き (ヨー方向, ピッチ方向) を示す. 次に, IMU から得られる観測値を用いて以下の仮定を置く.

- 3 次元自車速度ベクトルの大きさは車輪速と等しい.
- 方位 (ヨー角) 変化量はジャイロのヨーレイト積算値と等しい.
- ピッチ角はつねに 0 で近似できる (都心部では平坦な道路が多いため上下方向の速度変化は無視できる).
- クロックドリフトの時間変化は直線で近似できる (一般にクロックドリフトの時間変化は非常に緩やかであるため).




図 5 衛星数と方位推定結果の関係

Fig. 5 Estimated heading under the poor satellite condition.

これらは拘束条件として式 (6)–(9) のように表される.

$$|\mathbf{V}_t| = Vw_t \quad (6)$$

$$\theta_t = \theta_0 - \Delta t \sum_{t=0}^M \omega_t \quad (7)$$

$$\phi_t = 0 \quad (8)$$

$$\tau_t = \tau_0 - \alpha \cdot t \quad (9)$$

Vw_t は車輪速 (m/s), Δt は処理周期 (s), θ_0 は現時刻におけるヨー角 (rad), ω_t はジャイロのヨーレイト (rad/s), τ_0 は現時刻におけるクロックドリフト, α はクロックドリフト時間変化の傾きを示す. この中に含まれる未知数は θ_0 , τ_0 , α の 3 つである. さらに, 式 (5) と式 (6)–(9) を式 (4) に代入すると式 (10) が得られる.

$$V_{s_{t,i}} = Vw_t \left\{ Gx_{t,i} \cos \left(\theta_0 - \Delta t \sum_{t=0}^M \omega_t \right) + Gy_{t,i} \sin \left(\theta_0 - \Delta t \sum_{t=0}^M \omega_t \right) \right\} - c(\rho_0 - \alpha \cdot t) \quad (10)$$

式 (4) では (4 × 時系列データ数 M) 個の未知数が含まれていたのに対し, 時系列データに対する拘束条件を加えることにより, 式 (10) に含まれる未知数は 3 個 (θ_0 , ρ_0 , α) に削減された. 一方, 観測方程式の数は時系列データに比例して増加するため, 1 時刻あたりの衛星数が少ない場合でも安定的に解を得ることができる. すなわち, 従来手法では 1 時刻あたりの衛星数が 4 個以上必要であったのに対し, 提案手法では 1 時刻あたりの衛星数は最小 1 個の場合でも解を得ることができる.

図 5 に衛星数と解の関係の例を示す. 本図は実環境データの中で提案手法の効果を示す代表的なシーンを抽出したものであり, 図の最上段に衛星数, その下に観測方程式の解いて得られた方位 θ_0 を示す. 従来手法では衛星数が 4

以上の場合のみ方位が得られている．一方，提案手法では時系列データ数 M の増加にともなって方位が得られる場所が増加しており， $M = 10$ の場合は衛星数が最小 1 個の場合においても方位が得られていることが分かる．これは時系列データ全体に含まれる総衛星数が最低 10 個以上あるのに対し，未知数の数は 3 個であるため解が得られたことを示している．ただし，1 時刻あたりの衛星数が少ないほど観測誤差の影響が出やすい傾向にあるため，必ずしも精度良い方位が得られることを保証するものではないことに注意が必要である．なお， M の設定による方位精度への影響については， M が小さいほど方位誤差のばらつきが大きくなりやすく， M が大きいほど IMU の蓄積誤差やクロックドリフトの線形近似の影響により緩やかにバイアス性誤差が現れる傾向にあるため方位精度向上のためには適切な M の設定が必要である．最適な M の値は，IMU の精度，衛星受信機のクロックドリフトの変化傾向，ドップラーシフトのばらつき量などに依存するため，取得データなどに基づいた M の設定が望ましい．

3.3 絶対方位を考慮した Visual Odometry

従来の VO では式 (2) のコスト関数を最小化する自車軌跡・姿勢を算出していた．これに対し，提案手法では新たに GPS による絶対方位，および車輪速による 2 つのコスト関数を拘束条件としてそれぞれ追加することで，VO の方位蓄積誤差低減，および距離スケールの決定を行う．式 (11) に提案手法で用いるコスト関数を示す．

$$E_{total} = E_{cam} + E_{heading} + E_{scale} \quad (11)$$

E_{total} は最終的に最小化の対象となるコスト関数， E_{cam} はカメラ画像内の特徴点整合性に関する項 (式 (2))， $E_{heading}$ は方位の整合性に関する項， E_{scale} は進行距離の整合性に関する項であり，これら全体のコストを最小化することで拘束条件を考慮した最適な軌跡形状を推定する．以下にコスト関数 $E_{heading}$ ， E_{scale} について簡単に説明する．

$E_{heading}$ は GPS/IMU の時系列統合により推定した方位と VO で推定する方位との乖離度合に比例して増加するコスト関数であり，このコスト関数を導入することで VO の推定方位が GPS/IMU の方位と整合する値に収束する作用が働くため，VO のみの場合に生じていた方位の蓄積誤差を抑制することができる．具体的な算出方法を式 (12) に示す．

$$E_{heading} = \sum_{t=0}^M \delta_t (\theta_t - \theta'_t)^2 \quad (12)$$

θ_t は VO で推定する方位， θ'_t は GPS から推定した方位， δ_t は GPS の方位フラグをそれぞれ示す．方位フラグは GPS の方位推定の可否を示すフラグであり，方位推定結果が得られた場合は 1，得られなかった場合には 0 となる．

また， E_{scale} は VO で推定する自車位置の差分と車輪速で算出される進行距離との乖離度合に比例して増加するコスト関数である．このコスト関数を導入することで VO の軌跡長を車輪速の積算距離に近づける作用が働くため，進行距離を正しく保つことができる．算出方法を式 (13) に示す．

$$E_{scale} = \sum_{t=1}^M (Vw_t \Delta t - |\mathbf{x}_t - \mathbf{x}_{t-1}|)^2 \quad (13)$$

Vw_t は車輪速 (m/s)， Δt は処理周期 (s)， \mathbf{x}_t は自車位置を示す．

4. 評価実験

図 6 に評価コースを示す．評価コースは新宿周辺の約 500m の道路区間であり，周囲には高層ビルが立ち並ぶ．軌跡推定には単眼カメラ，IMU (車載ジャイロ，車輪速)，GPS 受信機 (出力 10 Hz) を利用し，リファレンスは Applanix 社の POSLV610 [13] を用いた (表 1)．POSLV610 は RTK-GPS，高精度ジャイロ，高分解能車輪速から構成される測位装置であり，都心部でも $\sim 0.3\text{m}$ 程度の高精度測位，および $\sim 0.1\text{deg}$ 程度の高精度姿勢推定が可能である．また，本評価では SXGA (1280 × 960) の画像情報を 15 fps で取得し，特徴点追跡のための画像特徴量は AKAZE 特徴 [14] と FAST 特徴 [15] を併用した．各時刻において，方位推定では過去 20 時刻分 (2 秒) の GPS/IMU データを入力として演算を行い，VO では過去 50 時刻分 (約 3.3 秒) の観測




図 6 評価実験コース (新宿)

Fig. 6 Evaluation course in Shinjuku city.

表 1 評価に使用した実験機器

Table 1 Sensors used in the experiment.

実験機器	製品
IMU (ジャイロ/車輪速)	車両 CAN バスから取得
GPS 受信機	NetR9
カメラ	XCD-SX90 (モノクロ, SXGA)
リファレンス	POSLV610

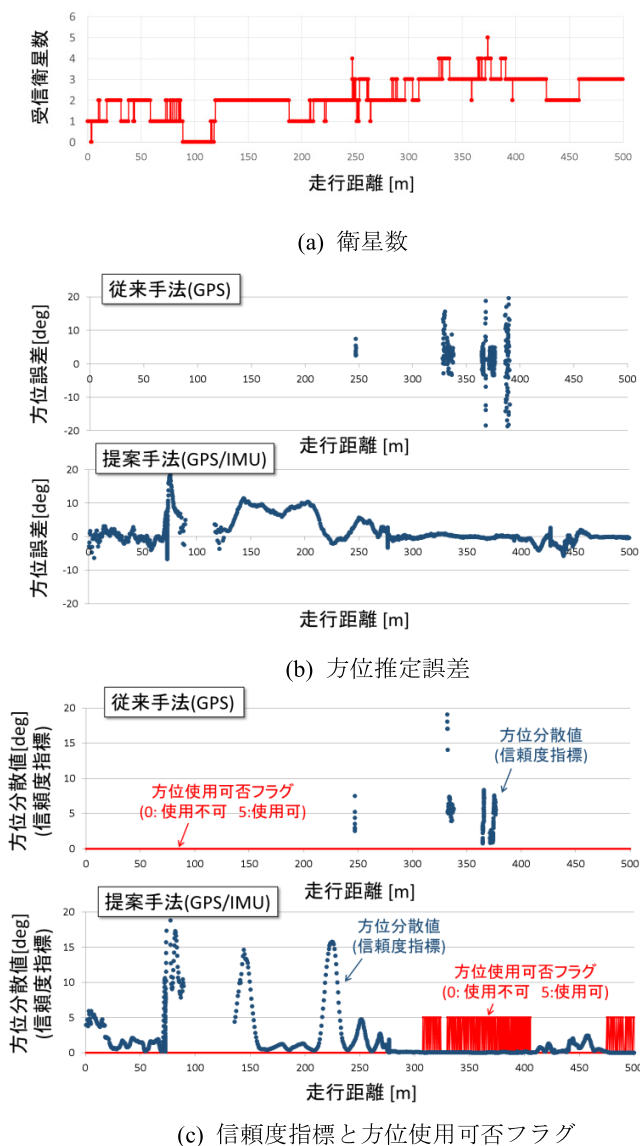


図 7 衛星数と方位結果

Fig. 7 Number of satellites and result of heading estimation.

情報を入力とした最適化処理を行うことで軌跡推定を行った。また、本評価ではマルチパス対策として、外れ値除去に基づいた衛星選択アルゴリズム RAIM [16] を採用した。

図 7 (a) に受信衛星数を示す。評価コースでは周囲の高層ビルにより衛星信号が遮蔽されやすいため衛星数はおおむね 4 未満であり、受信衛星数の中にはマルチパス信号も含まれている。図 7 (b) に従来手法 (GPS のみ) と提案手法 (GPS/IMU 統合) の方位推定誤差をそれぞれ示す。従来手法では衛星数が 4 以上の場合のみ方位推定結果が得られているのに対し、提案手法では衛星数が 4 未満の場所においても方位推定結果が得られていることが分かる。しかしながら、衛星数が少ないコース前半などにおいては大きな方位誤差の変動が見られるため、これをそのまま VO の方位補正に利用することは難しい。そこで本研究では信頼度に基づいた方位の使用可否判定を行い、精度の良い方位 (~ 0.5 deg 程度) を選別した。

図 7 (c) に従来手法と提案手法の信頼度指標および方位使用可否フラグをそれぞれ示す。信頼度評価では方位推定のばらつき度合に着目し、過去 20 時刻において得られた方位推定結果の分散値 (以下、方位分散値) を信頼度指標として用いた。なお、方位分散値は誤差成分のばらつき以外にも車両の動き (進行方位の変化) の影響も受けるため、車両の動きによる方位変動分はジャイロヨーレイトを用いて補正した。これにより方位分散値は方位誤差の変動のみを反映した値となる。図 7 (c) では方位分散値の閾値を 0.1 deg とし、方位の使用可否判定を行った結果を示す。従来手法では方位のばらつきが全体に大きいため、信頼度が高い方位が得られない (フラグ = 0) のに対し、提案手法では方位のばらつきが比較的小さいコース後半において信頼度が高い方位を得られている (フラグ = 5) が分かる。

図 7 から読み取れる提案手法の効果を 2 点あげる。1 点目は衛星数が 4 未満の場所でも精度良い方位の取得機会が得られたこと、2 点目は従来手法に比べ方位推定の誤差変動が低減していることがあげられる。誤差変動低減の理由として、時系列データ利用にともなう衛星数増加により衛星ごとの観測誤差を平均化する効果が生まれることに加え、観測情報の冗長性が増すほど RAIM の正確性が向上することなどが考えられる。一方、1 時刻あたりの衛星数が 1~2 の場合には上記効果の恩恵が減ることに加え、衛星配置の偏りによって誤差共分散が増大することで、高精度な方位を得られる可能性が低下する傾向にある。このようなシーンで方位精度の改善を行うためには、時系列データ数の最適化やマルチパス除去などの対策が必要であると考えられるが、図 5 の結果にも見られるように衛星数 1 の場合には衛星配置の偏りが誤差変動に及ぼす影響が大きいいため、実用的な方位精度を得るためには最低でも衛星数 2 以上の環境が望ましいと考えられる。

図 8 に軌跡推定結果を示す。4 つの軌跡はそれぞれ、VO の軌跡に GPS のみを用いた方位補正を行った従来手法の結果 (VO+GPS 方位)、IMU の軌跡に GPS/IMU を用いた方位補正を行った従来手法の結果 (IMU+GPS/IMU 統合方位)、VO の軌跡に GPS/IMU を用いた方位補正を行った提案手法の結果 (VO+GPS/IMU 統合方位)、そしてリファレンスを示す。各軌跡は起点をリファレンスと合わせたうえで描いている。軌跡推定結果の比較では、各従来手法は走行とともにリファレンスからのズレが拡大していくのに対し、提案手法ではリファレンスのズレはコース終盤においてもわずかである。最終地点においても提案手法の軌跡の到着点がリファレンスと最も近いことが分かる。

図 9 に各手法の方位誤差をそれぞれ時系列で示す。VO+GPS 方位ではコース全般にわたり方位補正ができないため、画像中特徴点位置の誤差などによってわずかに生じる方位誤差が走行とともに蓄積している。一方、提案




図 8 軌跡推定結果
Fig. 8 Result of trajectory estimation.




図 9 方位推定誤差
Fig. 9 Error of heading estimation.

手法では GPS による方位補正が可能であるため、方位誤差の蓄積が随時リセットされていることが分かる。また、IMU+GPS/IMU 統合方位では後半において方位補正が行われるが、それまでの区間における方位の蓄積誤差が大きい。

また、図 10 に各手法の軌跡誤差をそれぞれ時系列で示す。各種従来手法では方位誤差が大きな区間においてそれぞれ軌跡誤差の増加が見られる。一方、提案手法ではコース全体を通して方位誤差が低減しているため、軌跡誤差の増加が抑えられていることが分かる。

図 11、図 12 に 100 m 走行あたりに生じる方位誤差、軌跡誤差の値をそれぞれ示す。100 m 走行あたりに生じる

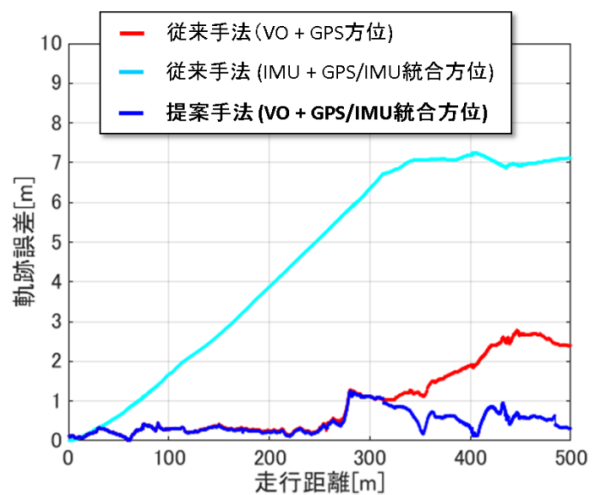


図 10 軌跡推定誤差
Fig. 10 Error of trajectory estimation.




図 11 100 m 走行あたりに生じる方位誤差
Fig. 11 Error of heading estimation per 100 m of driving.




図 12 100 m 走行あたりに生じる軌跡誤差
Fig. 12 Error of trajectory estimation per 100 m of driving.

軌跡誤差は、まず推定した軌跡を 100 m ごとに区切り、各 100 m 区間の始点をリファレンスと合わせたうえで終点におけるリファレンスからのズレをそれぞれ算出し、最後に各 100 m 区間で生じたすべての誤差の平均をとって算出し

た. 100 m 走行あたりに生じる方位誤差も同様の方法で算出した.

提案手法の方位誤差は, VO+GPS 方位に比べて約 3 割減, IMU+GPS/IMU 統合方位に比べて約 5 割減となっている. また, 提案手法の軌跡誤差は VO+GPS 方位に比べて約 3 割減, IMU+GPS/IMU 統合方位に比べて約 6 割減となっており, 提案手法では方位精度の改善により軌跡精度が向上したことが分かる. 以上より, 都心部における提案手法の効果が示された.

5. 結論

都心部における推測航法精度向上を目的とし, Visual Odometry (VO) と汎用センサ (IMU, GPS) の統合による推測航法を提案した. 提案手法では IMU と GPS の時系列データを統合することで, 衛星数が低下しやすい都心部における方位推定の頻度を向上し, さらに推定した方位に基づき VO の方位補正を行うことで都心部でも誤差が蓄積しにくい推測航法を実現した. 高層ビルが立ち並ぶ新宿にて評価を行った結果, 衛星数が低下時における方位推定の頻度向上を確認した. また, VO の方位補正の頻度増加により推測航法誤差は従来に比べ約 3 割以上低減した. 以上より都心部における提案手法の原理的な有効性を確認した.

都心部の推測航法精度改善により, RTK-GPS などによる絶対位置が得られない区間において位置精度を担保できる距離範囲が伸びるため, 高精度車両位置情報を用いた各種運転支援システムの可用性向上への寄与が期待される.

一方, 今後実用化に至るためにはさらなる測位の信頼性向上が必要不可欠である. 第一に, 実世界における多様な環境に対するロバスト性向上として, 天候や昼夜の照明変動, 周辺車両の動き, 見た目の特徴が少ないトンネル内などにおける VO の精度劣化対策, また, GPS を用いた方位推定部では最適な時系列データ数の動的な推定や方位使用可否判定の強化などが課題となる. また, 測位結果の誤差の程度を正確に把握するための信頼性モニタリング技術も実用アプリケーションにおいては重要な要素技術となる.

参考文献

- [1] Meguro, J., Ishida, H., Guo, C. and Kojima, Y.: Road Ortho-image Generation and Road Marking Detection using Conventional In-vehicle Sensors, *Proc. 20th ITS world congress*, Tokyo (2013).
- [2] Dai, L., Han, S., Wang, J. and Rizos, C.: A Study on GPS/GLONASS Multiple Reference Station Techniques for Precise Real-Time Carrier Phase-Based Positioning, *Proc. International Technical Meeting of ION GPS*, pp.392–403 (2001).
- [3] Alismail, H., Baker, L.D. and Browning, B.: Continuous trajectory estimation for 3D SLAM from actuated lidar, *Proc. Int. Conf. Robot. Autom. (ICRA)*, pp.6096–6101 (2014).
- [4] Nister, D., Naroditsky, O. and Bergen, J.: Visual,

odometry, *Proc. IEEE Conference on Computer Vision and Pattern Recognition* (June 2004).

- [5] Yamaguchi, K., Kato, T. and Ninomiya, Y.: Vehicle ego-motion estimation and moving object detection using a monocular camera, *Proc. 18th International Conference on Pattern Recognition*, pp.610–613 (2006).
- [6] Heng, L., Honegger, D., Lee, G.H., Meier, L., Tanskanen, P., Fraundorfer, F. and Pollefeys, M.: Autonomous Visual Mapping and Exploration with a Micro Aerial Vehicle, *Journal of Field Robotics*, Vol.31, pp.654–675 (2014).
- [7] Rehder, J., Gupta, K., Nuske, S. and Singh, S.: Global pose estimation with limited GPS and long range visual odometry, *2012 IEEE International Conference on Robotics and Automation*, pp.627–633 (May 2012).
- [8] 目黒淳一, 小島祥子, 鈴木徳祥, 寺本英二: GPS ドップラと慣性センサの統合による車両軌跡推定手法の提案, *情報処理学会論文誌*, Vol.53, No.1. pp.212–222 (2012).
- [9] Alonso, I.P., Llorca, D.F., Gavilán, M., Pardo, S.Á., García-Garrido, M.Á., Vlacic, L. and Sotelo, M.Á.: Accurate Global Localization Using Visual Odometry and Digital Maps on Urban Environments, *IEEE Trans. Intelligent Transportation Systems*, Vol.13, No.4, pp.1535–1545 (Dec. 2012).
- [10] Triggs, B., McLuchlan, P., Hartley, R. and Fitzgibbon, A.: Bundle adjustment – A modern synthesis, *Vision Algorithm: Theory and Practice*, Springer-Verlag LNCS (2000).
- [11] Marquardt, D.: An algorithm for least-squares estimation of nonlinear parameters, *SIAM Journal on Applied Mathematics*, Vol.2, pp.431–441 (1963).
- [12] van Grass, F. and Soloviev, A.: Precise velocity estimation using a stand-alone GPS receiver, *Journal of the Institute of Navigation*, No.4, pp.283–292 (2004).
- [13] 入手先 (<https://www.applanix.com/products/poslv.htm>).
- [14] Alcantarilla, P.F.: Fast Explicit Diffusion for Accelerated Features in Nonlinear Scale Spaces, *British Machine Vision Conference (BMVC)* (Sep. 2013).
- [15] Rosten, E., Porter, R. and Drummond, T.: Faster and better: A machine learning approach to corner detection, *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.32, pp.105–119 (2010).
- [16] Lee, Y.: Analysis of Range and Position Comparison Methods as a Means to Provide GPS Integrity in the User Receiver, *Proc. Institute of Navigation 42nd Annual Meeting* (June 1986).




武山 洪二郎 (正会員)

2004 年東京大学工学部卒業, 2007 年同大学大学院修士課程修了. 2007 年より豊田中央研究所勤務. 2015 年より東京海洋大学博士課程在籍. 画像, GPS, IMU 等の複数センサ統合による自己位置推定の研究に従事.



町田 貴史 (正会員)

1998年大阪大学工学部卒業，2000年奈良先端科学技術大学院大学修士課程修了，2005年同大学院博士課程修了．2002～2006年大阪大学助教，2006年より豊田中央研究所勤務．コンピュータグラフィックスと画像処理を用いたバーチャルリアリティの研究に従事．



小島 祥子 (正会員)

1993年名古屋大学工学部卒業，1995年同大学院修士課程修了，2015年同大学院博士課程修了．1995年より豊田中央研究所に勤務．衛星測位，走行環境理解，運転支援のための地図生成の研究に従事．



久保 信明

1996年北海道大学工学部卒業，1998年同大学院修士課程修了，2005年東京大学大学院博士課程修了．2008年より客員研究員としてスタンフォード大学に在籍，現在准教授として東京海洋大学に勤務．衛星測位技術全般，特にRTK測位およびマルチパス検出による高精度測位の研究に従事．