

特徴点地図と単眼カメラ画像の時系列照合による ロバスト位置推定手法の提案

武山 洪二郎^{1,a)} 加藤 武男¹ 後藤 邦博¹

受付日 2019年3月27日, 採録日 2019年10月3日

概要: 本研究では高度運転支援アプリケーションへの適用を目的とし, LiDAR より安価な単眼カメラと地図情報を用いて, 誤差 0.3m 相当の高精度位置推定技術の実現を目指す. 車載カメラ画像と地図による位置推定は, カメラ画像中の特徴と事前に生成した地図情報に含まれる特徴との照合を行うことで地図上の自車位置を推定する技術であるが, 周囲に特徴物が少ない場合など, 照合できる特徴の数が減少した場合に位置精度劣化の恐れがある. そこで本研究では, 車載カメラ画像の時系列データを利用することで照合の手がかりを増加させる手法を提案し, 環境変化に対する位置精度の頑健性を向上させた. 実験では実走行データを用いて, 照合できる特徴の数と位置精度との関係を検証した結果, 提案手法では照合できる特徴数の減少にともなう位置精度劣化の度合いが大幅に改善される傾向が見られた. 実環境に則した精度劣化シーン (構造物少, 照明変化) では, 位置誤差 0.3m 以下を満たす場所の割合は従来手法でそれぞれ 70%台であったのに対し, 提案手法では 100%近くまで改善可能であることを確認した.

キーワード: 位置情報, 地図, 単眼カメラ, 特徴点

Robust Localization via Sequential Map Matching Using Monocular Camera

KOJIRO TAKEYAMA^{1,a)} TAKEO KATO¹ KUNIHIRO GOTO¹

Received: March 27, 2019, Accepted: October 3, 2019

Abstract: This study proposes a method to provide the localization accuracy within 0.3m for the land vehicles. The localization via feature point matching between monocular camera and the pre-built map has a potential to achieve desi-meter accuracy without using expensive sensors such as LiDAR. The accuracy of localization is stable when the number of matched feature points is sufficient, however in a scene where the feature point matching is difficult to be performed due to the illumination change, the accuracy of localization can be degraded since the decrease of matched feature points makes the localization accuracy unstable. The proposed method uses feature points in the sequential time-series images to pseudo-increase the number of feature point matched with the map, which improves the robustness against the environment where the feature point matching is difficult to perform. The experiment showed the result that the proposed method has improved the accuracy of the localization when the number of matched feature points is reduced. Evaluation in the real environment with the illumination change or lack of texture, the availability of localization within 0.3m accuracy has been improved to around 100% with the proposed method while that of the conventional method is around 70%.

Keywords: localization, map, monocular camera, feature point

1. はじめに

近年, 自動車の安全性・利便性向上のため, 様々な運転

支援システムが提案されている. 特に, 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が提案されており, 死角からの他車との衝突回避や, レーンレベルでのナビゲーション, そして自動運転など, 高度な運転支援機能の実現が期待されている. 一般的なカーナビで求められる

¹ 株式会社豊田中央研究所
Nagakute, Aichi 480-1192, Japan

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

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 1 m を切る精度の位置情報が必要であり、特に自動運転ではレーン内の位置まで正しく知る必要があるため 0.3 m 程度の高い精度が求められる。このため、高精度な位置推定を行うための技術が重要となる。現状、高精度な位置情報を安定的に取得できる手法として、高性能な車載 LiDAR (レーザ測距計) を用いた位置推定手法 [1], [2] が知られている。この方法は LiDAR で計測した車両周囲の地物形状と地図 DB 内の地物形状との照合を行うことで地図上における自車位置を決定する手法である。誤差 0.1 m 程度の位置精度を安定的に得られるため、自動運転の実証実験などにおいて主に利用されているが、現状では LiDAR のセンサコストが高いため市販車への展開を行う際の課題となる。一方、LiDAR より安価なアプローチとして、車載カメラ画像を用いた位置推定手法が提案されている。この方法では、車載カメラ画像中に写る周囲の地物の特徴と、地図 DB 中の地物の特徴との照合を行うことで、地図 DB 上の自車位置を決定する。照合の手がかりとして利用できる特徴は多様であるが、実用性が高いアプローチとして 2 つの方法があげられる (図 1)。1 つ目は、路面マーク、信号機など、道路環境に存在する特定のオブジェクトを照合の手がかりとする方法 [3], [4], [5] である。この方法では、各オブジェクトの位置や形状を地図 DB に事前に登録し、その後、車載カメラ画像内におけるオブジェクト位置と地図 DB 中のオブジェクト位置との照合を行うことで地図 DB 上における自車位置の推定を行う。オブジェクトは照明変化などが生じた場合でも比較的ロバストに照合を行うことができるが、実際の走行環境では車両周辺に利用可能なオブジェクトが存在しない場所では位置推定を行うことができないため、自車位置が得られる場所が限定的となることが課題である。一方、2 つ目の方法として、特徴点を手がかりとした自車位置推定手法があげられる [6], [7], [8]。特徴点はオブジェクトに比べてミクロな特徴であり、一般的には建物の角やポールの先など画像中の輝度勾配が大きい箇所が抽出対象の点となる。特徴点はあらゆる地物上で自動的に抽出可能であるため、あらかじめ指定した特定の物体のみを利用するオブジェクトベースの方法に比べて利用シーンが大幅に増加することが利点となる。一方、特徴点はオブジェクトに比べて照明変化などによる物体の見え方の変化の影響を受けやすいため、地図 DB-カメラ画像間において正しい特徴点照合が困難となる場合がある。このようなシーンにおいて特徴点の誤照合を判定・排除することは比較的容易であるが、正しく照合できた特徴点の絶対数が少ない場合には位置推定精度が低下する傾向がある。

そこで本研究では、周辺環境の影響により地図 DB-カメラ画像間で照合できる特徴点数が減少した場合における位置推定精度の改善を行い、自動運転にも適用可能な位置精度 0.3 m を目指す。提案手法では車載カメラ画像の時系列

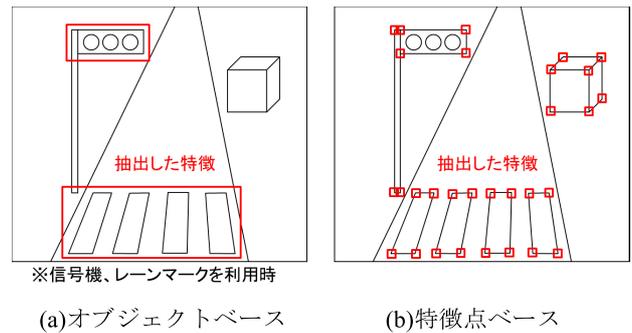


図 1 オブジェクトベースと特徴点ベースの違い
Fig. 1 (a) object based feature (b) point based feature. Comparison between object based feature and point based feature.

データを用いた照合を行うことで、照合に利用可能な特徴点数を見かけ上増加させることを基本アプローチとする。以下では、まずベースとなる従来手法 (2 章) についての説明を行い、次に提案手法 (3 章) について述べる。最後に、位置推定を行ううえで必要となる地図の生成手法 (4 章) について簡単に記した後、評価実験の結果について述べる (5 章)。

2. 従来手法

以下では従来手法として、地図 DB-カメラ画像間における特徴点照合による位置推定手法について説明する。この方法では、車載カメラ画像中の特徴点と、特徴点地図 DB 中の特徴点とのマッチングを行うことで自車位置を決定する。特徴点地図 DB は特徴点の 3 次元位置と画像特徴量の情報を有した地図 DB である (4 章を参照)。図 2 に特徴点を利用した位置推定手法の概要を示す。まず、特徴点地図 DB では広域にわたり分布する特徴点群の中から自車位置周辺の特徴点を選択する。ここでは自車位置の範囲がたまかに分かればよいため、GPS による位置情報や前時刻における位置推定結果を利用する。次に、車載カメラ画像から抽出した特徴点と特徴点地図 DB 中の特徴点との照合を行う。ここでは、SIFT [9] や AKAZE [10] などの画像特徴量に基づきカメラ画像-地図 DB 間において同一の特徴点を対応付ける。そして最後に、対応する特徴点どうしの整合性が最も高くなる自車位置・姿勢を決定する。ここでは「画像中の特徴点の奥行方向には実世界中の特徴点が存在する」、という仮定に基づき最適化を行う。具体的には、車載カメラ画像中の特徴点の奥行方向へ視線を引き、これらがそれぞれ対応する地図 DB 中の 3 次元特徴点と最も多く重なるような自車位置を探索する。

自車位置算出方法の詳細を以下に示す。特徴点を利用した位置推定では、画像中における特徴点の 2 次元位置と、地図 DB 中における特徴点の 3 次元位置を観測値として、自車の位置/姿勢の推定を行う。式 (1) に特徴点の 2 次元位置, 3 次元位置, 自車位置, 自車姿勢の関係を示す。

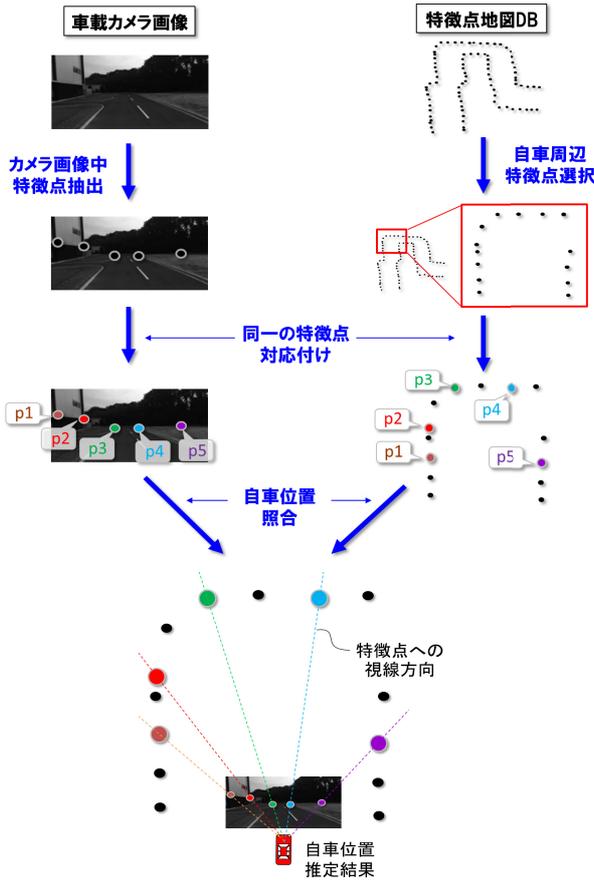


図 2 特徴点を用いた位置推定の基本的な流れ

Fig. 2 Overview of localization using feature point matching.

$$\mathbf{X}'_m = \mathbf{KR}[\mathbf{I} \mid -\mathbf{x}]\mathbf{X}_m \quad (1)$$

ただし,

$$\mathbf{R} = \begin{bmatrix} \cos \varphi & -\sin \varphi & 0 \\ \sin \varphi & \cos \varphi & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \theta & 0 & \sin \theta \\ 0 & 1 & 0 \\ -\sin \theta & 0 & \cos \theta \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \psi & -\sin \psi \\ 0 & \sin \psi & \cos \psi \end{bmatrix}$$

ここで、 \mathbf{X}'_m は車載カメラ画像中の特徴点 2 次元位置 (観測値)、 \mathbf{K} はカメラのキャリブレーション行列 (事前計測により既知)、 \mathbf{R} は自転車の姿勢 (ピッチ ϕ , ヨー θ , ロール ψ) を要素とした 3 次元回転行列 (未知数)、 \mathbf{x} は 3 次元自転車位置 (未知数)、 \mathbf{X}_m は地図 DB 中の特徴点 3 次元位置 (観測値)、 \mathbf{I} は 3×3 の単位行列、 m は特徴点インデックスを示す。式 (1) は画像-地図 DB 間でマッチングできた特徴点の数と同数だけ連立することができるため、式 (2) に示すコスト関数 E を最小化する \mathbf{x} , \mathbf{R} を求める非線形最適化問題に帰着し、Levenberg-Marquardt 法 [11] などを用いた収束演算により最適解の探索を行う。

$$E = \sum_{m=0}^{N-1} (\mathbf{X}'_m - \mathbf{KR}[\mathbf{I} \mid -\mathbf{x}]\mathbf{X}_m)^2 \quad (2)$$

(N は推定に用いる特徴点数)



(a)特徴が少ないシーン (b) 照明条件変化シーン

図 3 特徴点の照合が困難なシーン

Fig. 3 (a) textureless (b) illumination change. Scenes where feature point matching is degraded.

式 (2) では画像-地図 DB 間で照合できた特徴点の数 N に比例して観測方程式が増加するため、 N が多いほど誤差の平均化効果が増加し精度の良い解を得ることができる。逆に、周辺物が少ないシーンや照明条件の変動するシーンなど、地図 DB との特徴点の照合が困難な環境 (図 3) では位置推定の精度が劣化する恐れがある。

3. 提案手法

提案手法では車載カメラ画像の時系列データを利用することで、見かけ上の特徴点数を増加させることを基本コンセプトとする。図 4 に従来手法と提案手法の比較イメージを示す。従来手法では現時刻において観測した特徴点のみを照合に利用するのに対し、提案手法では時系列の車載カメラ画像に含まれる特徴点全体を照合に利用するため、特徴点数が一時的に減少した場合においても、照合の手がかりとなる特徴点を安定的に得ることができる。一方、時系列の観測値を単純に利用した場合、各時刻の車両位置・姿勢が未知数となり自由度が増加してしまうため、このままでは時系列データ利用の恩恵は得られない。そこで提案手法では、未知数を減らすための拘束条件として、ジャイロ・車輪速から得た方位変化 (ヨーレート)、車速を利用した。これにより、時系列データ利用にともなう未知数増加を回避でき、観測値増加の恩恵を受けることが可能となるため、1 時刻あたりに照合可能な特徴点数が少ないシーンにおいても安定的に高精度位置推定が可能となる。

以下に具体的な自転車位置算出方法を示す。提案手法ではまず式 (1) を時間方向に連立して式 (3) を得る。

$$\mathbf{X}'_{t,m} = \mathbf{KR}_t[\mathbf{I} \mid -\mathbf{x}_t]\mathbf{X}_m \quad (3)$$

ただし,

$$\mathbf{R}_t = \begin{bmatrix} \cos \varphi_t & -\sin \varphi_t & 0 \\ \sin \varphi_t & \cos \varphi_t & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos \theta_t & 0 & \sin \theta_t \\ 0 & 1 & 0 \\ -\sin \theta_t & 0 & \cos \theta_t \end{bmatrix} \times \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \psi_t & -\sin \psi_t \\ 0 & \sin \psi_t & \cos \psi_t \end{bmatrix}$$

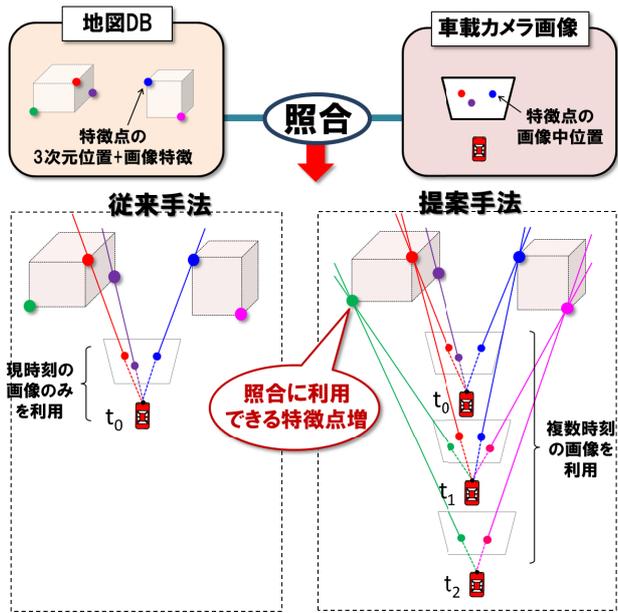


図 4 提案手法の基本コンセプト
Fig. 4 Key idea of the proposed method.

ここで、 $\mathbf{X}'_{t,m}$ は画像中の時系列の特徴点 2 次元位置、 \mathbf{K} はカメラのキャリブレーション行列、 \mathbf{R}_t は時系列の自転車姿勢 (ピッチ ϕ_t , ヨー θ_t , ロール ψ_t) を要素とした 3 次元回転行列、 \mathbf{x}_t は時系列の 3 次元自転車位置、 \mathbf{X}_m は地図 DB 中の特徴点 3 次元位置 (観測値)、 \mathbf{I} は 3×3 の単位行列、 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。式 (1) は現時刻で観測できる特徴点数 N と同数だけ式を連立できるのに対し、式 (3) は各時刻で観測できる特徴点数の総和と同数だけ式を連立できるため、見かけ上の拘束が増えるが、未知数 \mathbf{x}_t 、 \mathbf{R}_t は利用する時系列データ数に比例して増加するため、このままでは式 (3) の不定性は式 (1) から本質的に変化しない。このため、提案手法では時系列データ利用にともなう未知数増加を回避するため以下の拘束条件 (式 (4)、式 (5)) を設定する。

$$\mathbf{x}_t = \mathbf{x}_0 - \Delta \mathbf{x}_t \quad (4)$$

ただし、

$$\Delta \mathbf{x}_t = \begin{bmatrix} \sum_{t1=1}^t V_{t1} \cos \left(\theta_0' - \Delta t \sum_{t2=1}^{t1} \omega_{t2} \right) \\ \sum_{t1=1}^t V_{t1} \sin \left(\theta_0' - \Delta t \sum_{t2=1}^{t1} \omega_{t2} \right) \\ \sum_{t1=1}^t V_{t1} \sin (\phi_1') \end{bmatrix},$$

$$\theta_0' = \theta_1' + \omega_1 \Delta t$$

$$\begin{bmatrix} \phi_t \\ \theta_t \\ \psi_t \end{bmatrix} = \begin{bmatrix} \phi_0 \\ \theta_0 - \Delta t \sum_{t1=1}^t \omega_{t1} \\ \psi_0 \end{bmatrix} \quad (5)$$

式 (4) は時系列の自転車位置についての拘束条件であり、ジャイロと車輪速から算出した走行軌跡 $\Delta \mathbf{x}_t$ によって各時刻間の自転車位置変化を拘束している。式 (4) 中、 \mathbf{x}_0 は現時刻における自転車位置、 V_t は車輪速、 ω_t はジャイロのヨーレート、 ϕ_1' 、 θ_1' はそれぞれ前タイムステップにおける ϕ_0 (ピッチ)、 θ_0 (ヨー) の推定結果であり、 θ_0' は θ_1' とヨーレートから算出した現時刻におけるヨー角の予測値を示す。式 (4) 中、未知数は \mathbf{x}_0 のみであり、その他はすべて既知の値である。すなわち、拘束条件によって、時系列データ数に比例して増加していた未知数 \mathbf{x}_t が 1 つの固定された未知数 \mathbf{x}_0 に置き換えられたことを示す。

また、式 (5) は時系列の自転車姿勢についての拘束条件であり、ジャイロのヨーレートによって各時刻間の自転車方位 (ヨー) の変化を用いて拘束し、ピッチ、ロールについては急激な変化をしないことを前提として一定値として拘束している。式 (5) において、 ϕ_0 、 θ_0 、 ψ_0 は現時刻における自転車の姿勢 (ピッチ、ヨー、ロール) を示す。式 (5) 中、未知数は ϕ_0 、 θ_0 、 ψ_0 であり、その他はすべて既知の値である。すなわち、拘束条件によって、時系列データ数に比例して増加していた未知数 ϕ_t 、 θ_t 、 ψ_t が 1 つの固定された未知数の組 ϕ_0 、 θ_0 、 ψ_0 に置き換えられたことを示す。

以上にあげた式 (4)、式 (5) を式 (3) に代入することで、時系列データ数 $\times 6$ 個ある未知数 \mathbf{x}_t 、 ϕ_t 、 θ_t 、 ψ_t を 6 個の未知数 \mathbf{x}_0 、 ϕ_0 、 θ_0 、 ψ_0 に置き換えることができる。これにより、時系列データ利用にともなう未知数増加を抑えつつ、連立できる観測方程式の数を増加することができるため、1 時刻あたりに照合できる特徴点の数が少ない場合においても精度良い推定を行うことが可能となる。ただし、観測方程式を解くためには、時系列データ全体で照合できた特徴点数が 6 以上となる必要があるため、強烈な照明変化や、地図 DB にない車両などの移動物により画像の大部分が遮蔽されることにより、照合可能な特徴点が完全に喪失する状態が続いた場合には提案手法の効果が得られないことには留意する必要がある。

提案手法では従来手法と同様に最小二乗法を用いて \mathbf{x}_0 、 ϕ_0 、 θ_0 、 ψ_0 の最適化を行う。式 (6) に最小二乗法のコスト関数を示す。Levenberg-Marquardt 法による収束演算を行い、式 (6) を最小化する \mathbf{x}_0 、 ϕ_0 、 θ_0 、 ψ_0 を探索することで最適解を得ることができる。

$$E = \sum_{t=0}^{M-1} \sum_{m=0}^{N-1} (\mathbf{X}'_{m,t} - \mathbf{K} \mathbf{R}_t [\mathbf{I} | -\mathbf{x}_t] \mathbf{X}_m)^2 \quad (6)$$

(M, N はそれぞれ時系列データ数、推定に用いる特徴点数)

4. 地図 DB 生成方法

特徴点地図 DB は特徴点の 3 次元座標 (絶対位置座標) と画像特徴量を格納した地図 DB であり、特徴点を用いた

位置推定を行う際に必要となる。特徴点地図 DB に含まれる特徴点の 3 次元位置は位置推定精度に影響を与えるためその算出方法は重要となる。そこで本研究では画像情報、LiDAR、高精度位置計測装置 POSLV [12] を併用することにより高精度な特徴点地図 DB を生成した。POSLV は RTK-GPS、高精度ジャイロ、高精度車輪速を利用することで誤差数 cm 程度の測位が可能な位置計測システムである。

図 5 に特徴点 3 次元位置の算出手順を示す。まず AKAZE [10] を用いて画像中の特徴点の抽出を行う。画像中の特徴点位置からは自車から特徴点への方向を知ることができるが、特徴点の奥行き方向の位置は未知である。そこで、LiDAR を用いて特徴点の奥行き方向の位置（自車-特徴点間の距離）を取得する。これにより、自車と特徴点の

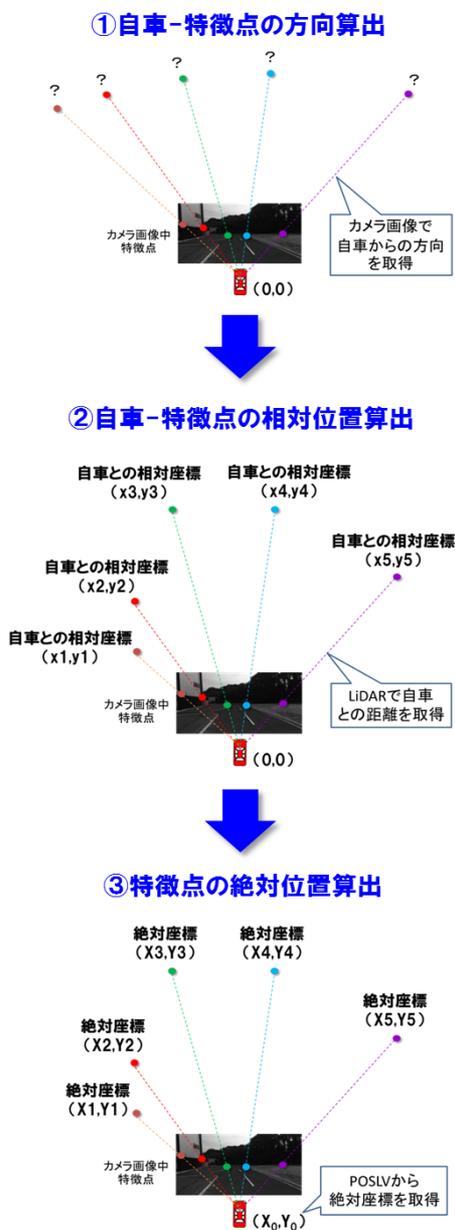


図 5 特徴点地図 DB の生成方法

Fig. 5 Construction of 3D feature point map.

相対的な位置関係を知ることができるが、この時点では地図 DB に必要な特徴点のグローバルな位置情報（絶対位置）は得られない。そこで、POSLV を用いて自車の絶対位置・姿勢を取得し、そこから特徴点の絶対位置（3 次元）を算出する。この手順を広域の走行データで繰り返すことで、画像特徴（AKAZE）と 3 次元位置情報を持った特徴点地図 DB が生成される。

なお、本研究では POSLV, LiDAR など高価なセンサ構成で特徴点地図 DB 生成を行ったが、画像情報のみを用いた特徴点 3 次元位置算出方法 [13], [14] もこれまで多く研究されており、近年では飛躍的な性能向上が確認されている。このため、近い将来には画像情報のみで構築した高精度な特徴点地図 DB の実利用を想定している。

5. 実験

以下に実験機器について記す。車載カメラ画像は安全システム用途として市販車両に搭載される前向きカメラ相当（画角 50 度）の画像を用いた（図 6）。車速、ヨーレートは車両の CAN 情報から得られる車輪速、ジャイロを用いて取得し、自車位置のリファレンスは POSLV [12] を用いた。また、特徴点地図 DB は 4 章に記した方法で事前に生成したものを利用した。各センサの入力周期はカメラ：66.6 ms, POSLV：10 ms, 車輪速・ジャイロ：12 ms であり、すべてを 66.6 ms で同期して評価を行った。

本研究では提案手法の有効性を検証するため、2 つの評価実験（実験①、実験②）において、それぞれ従来手法（現時刻の車載カメラ画像のみを用いた位置推定）と提案手法（過去 10 時刻分の車載カメラ画像を用いた位置推定）の比較評価を行った。

実験①では画像-地図 DB 間で照合できた特徴点の数と位置精度との関係を定量的に評価することで特徴点数の減少に対する提案手法のロバスト性を検証した。また、実験②では周囲に特徴点を抽出できる立体物が少ない場合や照明変化が生じた場合における位置精度を調査することで、実際のシーンにおける精度劣化要因に対する提案手法のロバスト性を検証した。以下では実験①、実験②の方法と結果についてそれぞれ述べる。

5.1 実験①：特徴点数減少に対するロバスト性評価

実験①では、照合できる特徴点数 N が比較的多い環境



図 6 車載カメラ画像

Fig. 6 In-vehicle camera image.

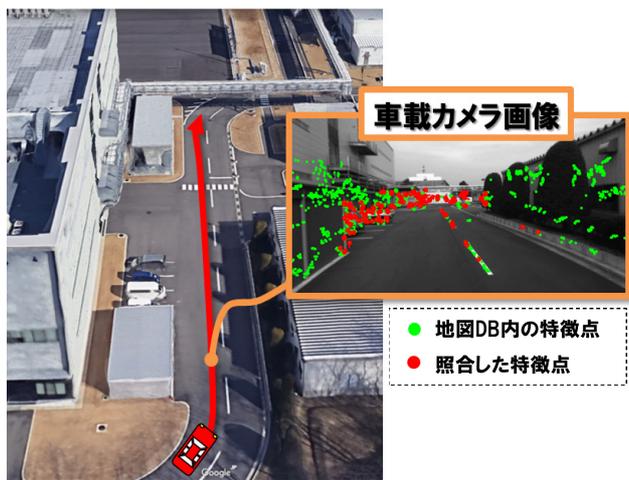


図 7 実験①の評価コース

Fig. 7 Evaluation course of experiment-1.

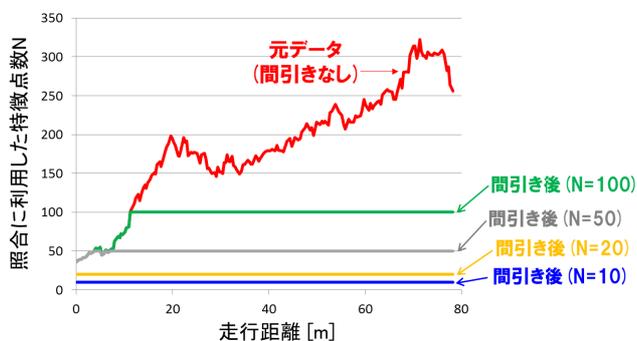


図 8 模擬評価のため生成した特徴点数 N のパターン

Fig. 8 Evaluation patterns of number of matched feature points.

において、 N を段階的に間引くことで特徴点の照合が困難な環境を模擬的に生成した。各 N における位置精度をそれぞれ評価することで、特徴点数の減少に対する提案手法のロバスト性を定量的に把握した。

【評価方法】

図 7 に評価コースを示す。コースは全長約 80m であり、周囲には構造物が存在し比較的多数の特徴点を照合できる環境である。図中右側の画像はコース中における車載カメラ画像であり、画像内の緑の点は特徴点地図 DB 内の特徴点を車載カメラ画像中に投影したものであり、赤の点はそのなかでカメラ画像中の特徴点と照合できたものを示している。照合できた特徴点 (赤点) は各時刻あたり平均 180 点程度である。

以下に、画像-地図 DB 間で照合できた特徴点数 N を間引いて模擬データを生成する方法について述べる。図 8 に元データにおける特徴点数 N と、段階的な間引き処理後の特徴点数 N をそれぞれ示す。元データでは走行コース中で $N = 50 \sim 350$ 個程度で推移するのに対し、模擬環境ではここから各時刻ごとに照合できた特徴点をランダムに間引き、それぞれ $N = 100, 50, 20, 10$ 個まで一律に減ら

元データ (特徴点数 N 間引きなし)

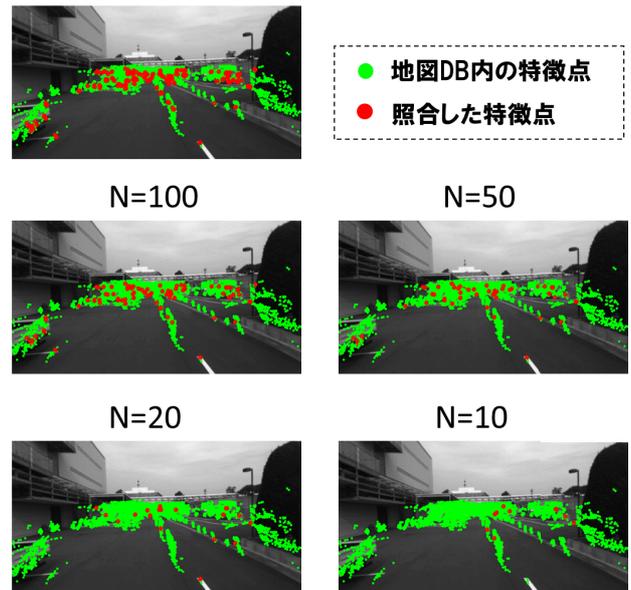


図 9 照合できた特徴点数 N の変化の様子

Fig. 9 Evaluation patterns displayed in camera view.

したパターンを生成した。ただし、元データ中の特徴点数が間引き後の特徴点数よりも小さい場合は、特徴点の間引き処理は行わないものとする (走行開始直後、 $N = 100, N = 50$ が該当)。図 9 に模擬環境における特徴点照合の例を示す。元データでは照合できた特徴点 (赤点) が比較的多く見られるのに対し、模擬環境ではそれらが減少している様子が分かる。なお、特徴点の時系列データを用いる提案手法では、まず間引く前の特徴点を時系列で蓄積した後、現時刻において従来手法が利用している特徴点 (ランダムに間引かれたもの) と同一の特徴点のみを過去最大 10 時刻まで遡って利用した。

【結果】

図 10 に従来手法と提案手法の位置誤差を示す。従来手法では N の減少にともない誤差のばらつきが大きくなっているのに対し、提案手法では従来手法に比べ N の減少にともなう誤差のばらつき度合いが軽減されていることが分かる。図 11 に位置誤差の定量評価指標として標準偏差 σ を示す。従来手法に比べて提案手法では全体的に低減されており、特に $N = 10$ の場合においては大幅な改善が見られる。提案手法では時系列データ利用により、従来手法より照合できる特徴点の数が見かけ上増加するため、1 時刻あたりに照合できる特徴点数が減少した場合においても誤差の低減効果が得られていると考えられる。コース全体のなかで、位置誤差が 0.3m 以下であった場所の割合 (場所率) を図 12 に示す。従来手法では N の減少に従い加速度的に場所率が低下しているのに対し、提案手法では場所率が全体的に底上げされており、 $N = 10$ の場合においても 95% 程度を維持しており、 N の減少にともなう場所率の低

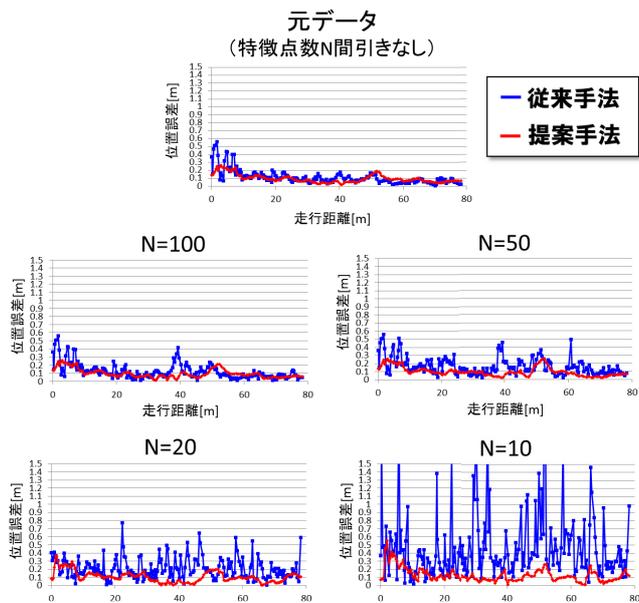


図 10 位置誤差

Fig. 10 Position error.

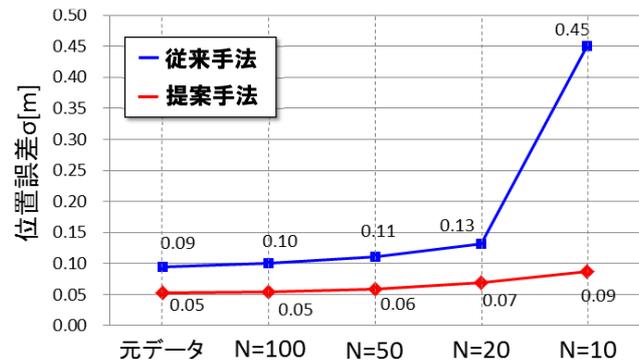


図 11 特徴点数と位置誤差 σ の関係

Fig. 11 Relationship between number of matched feature points and variation of position error.

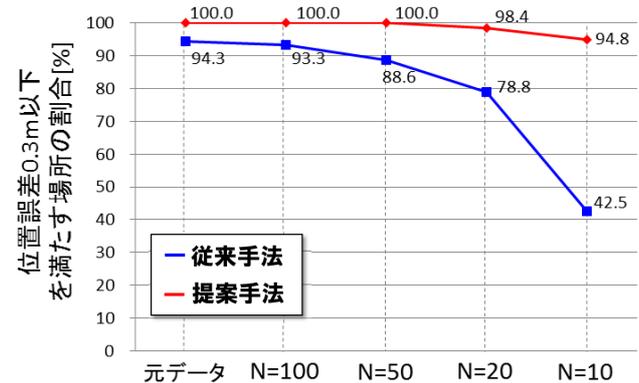


図 12 特徴点数と位置誤差 0.3m 以下の場所率の関係

Fig. 12 Relationship between number of matched feature points and availability of positioning with 0.3m accuracy.

下度合が改善されていることが分かる。これにより、特徴点の照合数が大きく低下した場合においても、提案手法を用いることで安定的に誤差 0.3m 内の位置推定を行うこと

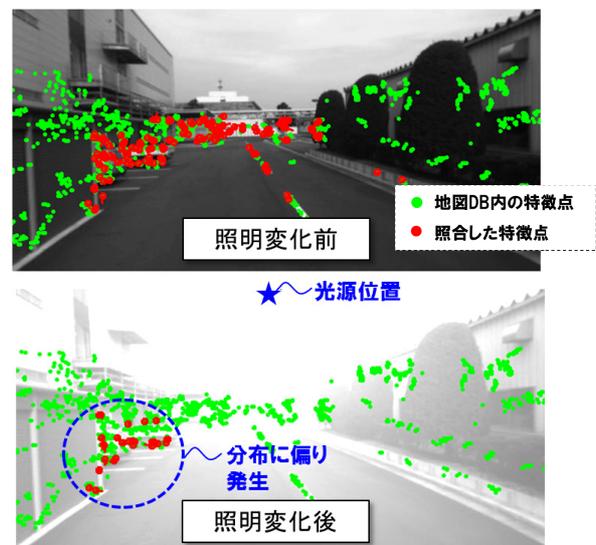


図 13 照明変化前後の画像の比較

Fig. 13 Simulation of illumination change.

ができる可能性を確認した。

5.2 実験②：実際の精度劣化要因に対するロバスト性評価

実験①では特徴点全体に対し一律にランダムな間引き処理を行うことにより特徴点の照合が困難な環境を模擬したが、実環境では周辺環境や照明条件により照合できる特徴点の分布は多様に変化する可能性がある。そこで実験②では実環境において特徴点の照合が困難となる代表的なシーンとして、太陽光による照明変化が生じる場合と、周囲に構造物が少ない場合において、それぞれ提案手法の効果を検証した。太陽光による照明変化が生じる場合については、実験①で用いた画像上に人為的に光源を付与することで模擬的に生成した画像を用い、周囲に構造物が少ない場合については実際の走行シーンにおいて取得した画像を用いた。

5.2.1 照明変化に対するロバスト性評価

実際の走行シーンでは、屋内外の出入りや太陽光の直射などによる画像の大幅な輝度変化にともない、画像-地図DB間の照合が困難となり位置精度が劣化する可能性がある。そこで本項の評価では、実験①で用いた車載カメラ画像に対し人為的に照明変化を加えることで特徴点照合が困難なシーンを模擬的に生成し、位置精度への影響を検証した。

【評価方法】

以下に、元画像に対し照明変化を加える方法について述べる。図 13 に元画像と照明変化後の画像を示す。照明変化後の画像では、光源位置を画像中央上に配置し、光源からの距離に反比例するように各画素に輝度を加算することで太陽光を模擬した。また、輝度変化の処理は各時刻の画像についてすべて同様に行った。



図 14 照合できた特徴点数 N

Fig. 14 Number of matched feature points.

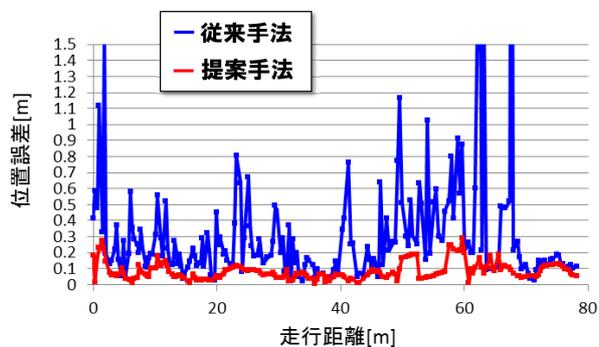


図 15 位置誤差

Fig. 15 Position error.

図 13 中の赤点は照合できた特徴点を示す。照明変化を加えた後では照明変化に頑健な特徴点のみが残るため、ランダムに間引き処理を行った場合 (図 9) とは異なり、照合できた特徴点の分布に偏りが生じていることが分かる。

図 14 に照明変化付与とともに、照合できた特徴点数 N の変化の様子を示す。照明変化前において N の平均は 180 点程度であるのに対し、照明変化後では N の平均は 20 点程度まで大幅に減少し、10 点未満となる場合も随所に見られる。実環境における多様な走行シーンでは逆光やトンネル出口におけるカメラ自動露光調整の遅れなどにより、同様の状況が容易に発生する可能性がある。

【結果】

図 15 に照明変化後における従来手法と提案手法の位置誤差を示す。従来手法ではコース全体にわたり位置誤差のばらつきが大きいのに対し、提案手法では位置誤差のばらつきが大幅に低減されていることが分かる。

図 16 に標準偏差 σ を示す。また、図 17 にコース全体のなかで、位置誤差が 0.3m 以下であった場所の割合 (場所率) を示す。標準偏差 σ は提案手法では従来手法の 1/8 程度まで低減しており、誤差のばらつきが大幅に改善さ

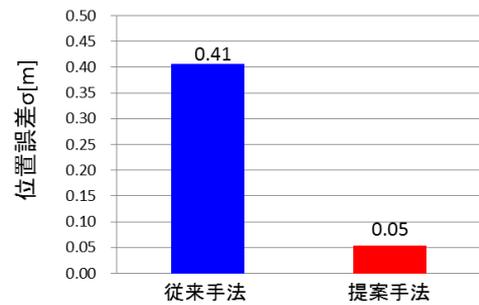


図 16 位置誤差 σ

Fig. 16 Variance of position error.

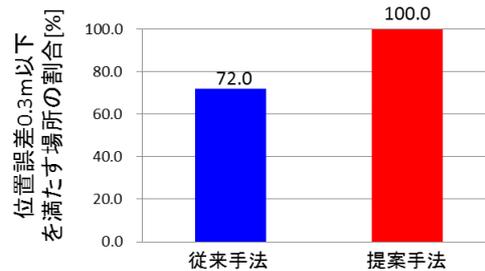


図 17 位置誤差 0.3m 以下の場所率

Fig. 17 Availability of positioning with 0.3m accuracy.

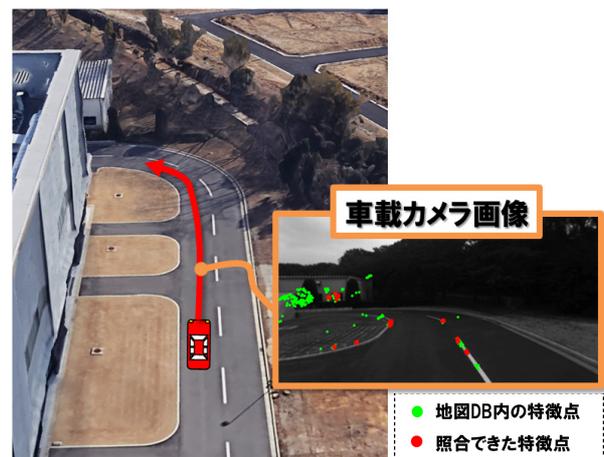


図 18 評価コース (周囲に構造物少)

Fig. 18 Evaluation course in texture-less scene.

れていることが分かる。また、場所率についても従来手法 72% に対し提案手法では 100% まで改善されており、照明変化により照合できた特徴点の位置に偏りが生じた場合であっても提案手法の有効性を確認することができた。

5.2.2 周囲に構造物が少ない環境に対するロバスト性評価

周囲に特徴点を抽出できる構造物が少ない場合には、画像-地図 DB 間で照合可能な特徴点数が減少し位置精度が劣化する可能性がある。そこで本項の評価では、周囲に特徴点を抽出可能な構造物が少ない場合において、位置精度への影響を評価した。

【評価方法】

図 18 に評価コースを示す。コースは全長約 45m であり、周囲に特徴点を抽出できる構造物が少ない環境である。車

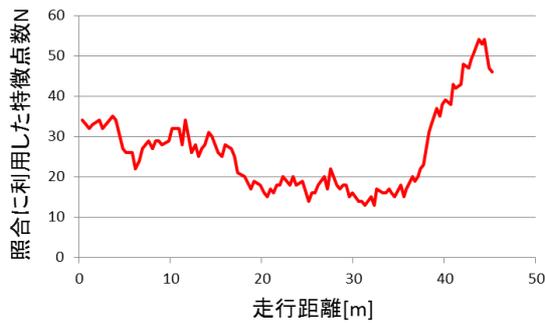


図 19 照合できた特徴点数 N

Fig. 19 Number of matched feature points.

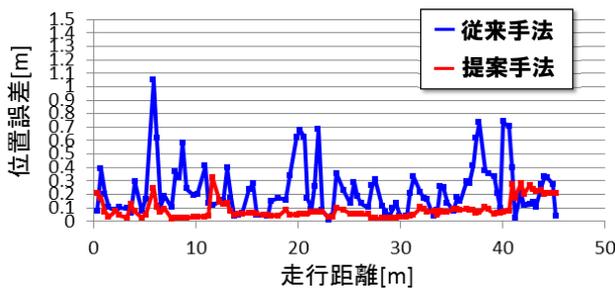


図 20 位置誤差

Fig. 20 Position error.

載カメラ画像中では、左側にわずかに建物が見える程度であり、中央から右側にかけては道路面や草木など特徴点の抽出が困難な領域が大半を占めていることが分かる。図 19 に照合できた特徴点数 N を示す。 N は各時刻あたり平均 26 点程度、最小 10 点付近まで低下しており、図 7 の評価コース（平均 180 点程度）に比べて大幅に少ないことが分かる。実環境における多様な走行シーンにおいても、このように周囲に構造物が少ない郊外などのシーンでは N が 10 付近まで低下するシーンは容易に発生すると推測される。また、都心部のような環境においても、カメラ前方に車両などの（地図情報にはない）移動物が大きく写り込んだ場合などにおいて同様の状況が発生すると考えられる。

【結果】

図 20 に従来手法と提案手法の位置誤差を示す。従来手法では随所で 0.3m を超える誤差が現れているのに対し、提案手法では誤差のばらつきが大幅に抑えられていることが分かる。

図 21 に位置誤差の標準偏差 σ を示す。また、図 22 にコース全体のなかで位置誤差が 0.3m 以下であった場所の割合（場所率）を示す。提案手法では従来手法に比べて σ が 1/2 以下に低減されており、位置精度が安定化していることが分かる。また、場所率も従来手法 74% に対し提案手法では 99% まで改善されており、周囲に特徴点抽出可能な構造物が少ない実環境においても提案手法の有効性を確認することができた。

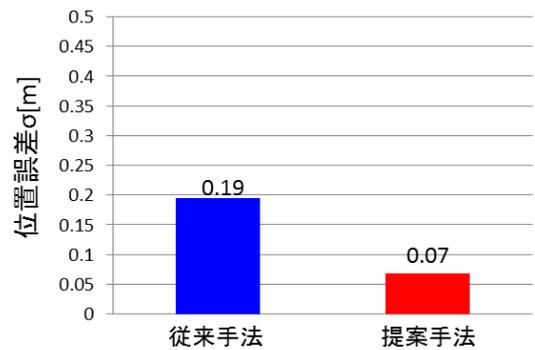


図 21 位置誤差 σ

Fig. 21 Variance of position error.

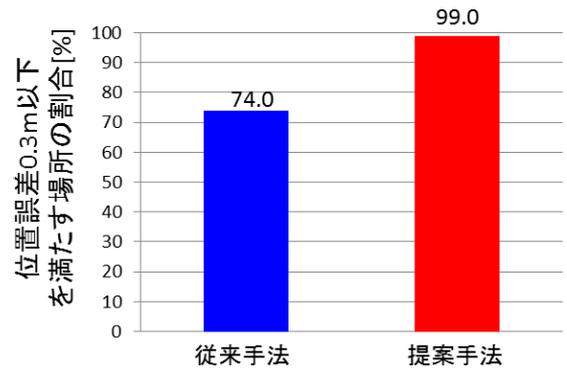


図 22 位置誤差 0.3m 以下の場所率

Fig. 22 Availability of positioning with 0.3m accuracy.

6. まとめ

本研究では、自動運転などの高度運転支援に適用可能となる誤差 0.3m 以下の位置推定を目的とし、カメラ画像と地図 DB の照合による位置推定の精度向上に取り組んだ。カメラ画像-地図 DB の照合による位置推定精度向上のためには、照合できる特徴点の数を増加することが重要となるが、従来では周辺物が少ないシーンや照明変動が生じるシーンでは照合できる特徴点数が減少し位置精度が劣化するという問題があった。これに対し、本研究では時系列の車載カメラ画像の情報をジャイロ・車輪速の観測値とともに利用する手法を提案した。提案手法では複数時刻の特徴点を同時に照合に利用できるため、1 時刻あたりに照合可能な特徴点数が減少するシーンにおいても安定的に照合の手がかりとなる特徴点を確保できるため、位置精度の劣化を防ぐことができる。

実験では、照合できる特徴点数 N と位置精度の関係を検証した結果、 N によらず提案手法は従来手法に比べて位置精度の改善が見られ、特に N が減少するほど提案手法の効果は増加する傾向が見られた。また、実環境に則した評価として、周囲に構造物が少ない場合と照明変化が生じる場合における位置精度を評価した結果、いずれの場合においても提案手法では従来手法に比べ位置精度の改善が見られ、位置誤差 0.3m 以下の場所率は従来手法でそれぞれ

70%台であったに対し、提案手法では100%近くまで改善されることを確認した。

今後、提案手法をベースに、カメラ画像による位置推定をさらにブラッシュアップしていくことで、自動運転にも適用可能な位置推定装置をLiDARよりも安価に提供できることが期待できる。また、特徴点数の低減に対するロバスト性が高い提案手法の特性を活かし、地図DB中の特徴点の密度を意図的に減らすことで地図DBのデータ量削減を行うなどの利用法も考えられる。

実用化に向けた残存課題としては、位置推定の信頼性判定手法の確立、より安価かつ簡易な地図生成手法の確立、多様な走行環境における網羅的な精度検証などがあげられる。

参考文献

- [1] Wolcott, R.W. and Eustice, R.M.: Fast LIDAR localization using multiresolution Gaussian mixture maps, *Proc. International Conference on Robotics and Automation (ICRA)* (2015).
- [2] Baldwin, I. and Newman, P.: Road vehicle localization with 2D push-broom LIDAR and 3D priors, *Proc. International Conference on Robotics and Automation (ICRA)* (2012).
- [3] Schreiber, M., Knoppel, C. and Franke, U.: LaneLoc: Lane marking based localization using highly accurate maps, *Proc. IEEE Intelligent Vehicles Symposium (IV)* (2013).
- [4] Wolcott, R.W. and Eustice, R.M.: Visual localization within LIDAR maps for automated urban driving, *Proc. IEEE/RSJ International Conference on Intelligent Robots and Systems* (2014).
- [5] Pink, O.: Visual map matching and localization using a global feature map, *Proc. CVPR Workshop* (2008).
- [6] Lim, H., Sinha, S.N., Cohen, M.F. and Uyttendaele, M.: Real-time image-based 6-DOF localization in large-scale environments, *Proc. CVPR* (2012).
- [7] Donoser, M. and Schmalstieg, D.: Discriminative Feature-to-Point Matching in Image-Based Localization, *Proc. CVPR* (2014).
- [8] 武富貴史, 佐藤智和, 横矢直和: 拡張現実感のための優先度情報を付加した自然特徴点ランドマークデータベースを用いた実時間カメラ位置・姿勢推定, *電子通信学会論文誌 D*, Vol.92, No.8, pp.1440–1451 (2009).
- [9] Lowe, D.G.: Distinctive image features from scale-invariant keypoints, *International Journal of Computer Vision*, Vol.60, No.2, pp.91–110 (2004).
- [10] Alcantarilla, P.F.: Fast explicit diffusion for accelerated features in nonlinear scale spaces, *Proc. British Machine Vision Conference (BMVC)* (2013).
- [11] arquardt, D.: An algorithm for least-squares estimation of nonlinear parameters, *SIAM Journal on Applied Mathematics*, Vol.2, pp.431–441 (1963).
- [12] POSLV Specifications, available from ([https://www.applanix.com/pdf/POSLV_Specifications_oct.2016_yw_\(1\).pdf](https://www.applanix.com/pdf/POSLV_Specifications_oct.2016_yw_(1).pdf)) (accessed 2017-10-06).
- [13] Liu, B., Yu, M., Maier, D. and Männer, R.: An Efficient and Accurate Method for 3D-Point Reconstruction from Multiple Views, *International Journal of Computer Vision*, Vol.65, No.3, pp.175–188 (2005).
- [14] Agarwal, S., Snavely, N., Simon, I., Seitz, S.M. and Szeliski, R.: Building rome in a day, *Proc. International Conference on Computer Vision (ICCV)* (2009).



武山 洪二郎 (正会員)

豊田中央研究所。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、2018年東京海洋大学大学院博士課程修了。2007年より豊田中央研究所勤務。画像、GPS、IMU等の複数センサ統合をアプローチとした自動車の位置推定、運転支援のための地図生成の研究に従事。



加藤 武男

豊田中央研究所。1990年名古屋大学工学部卒業、1992年同大学大学院工学研究科修士課程修了、1992年より豊田中央研究所勤務、1999年～2000年MIT客員研究員。画像認識、機械学習、走行環境理解のための研究に従事。



後藤 邦博

豊田中央研究所。2001年岐阜大学工学部卒業、2003年同大学大学院修士課程修了、2006年同大学院博士課程修了。2008年より豊田中央研究所に勤務。画像認識を用いた予防安全システム、運転支援のための地図生成の研究に従事。