

## 車載カメラ画像と地図 DB の時系列照合による自己位置推定

武山洪二郎<sup>1</sup> 加藤武男<sup>1</sup> 後藤邦博<sup>1</sup>

**概要：**本研究では自動運転への適用を目的とし、汎用的な車載カメラを用いて、シームレスかつ高精度(誤差 0.3m)な位置推定技術の実現を目指す。車載カメラ画像を用いた位置推定は、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する手法を提案し、環境変化に対する位置精度の安定性を向上した。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の関係を検証した結果、照合できる特徴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、最も劣悪な環境において位置誤差 0.3m 以下を達成できる場所の割合は従来手法の 86.8%から 95.6%へと向上した。

### Localization of land vehicle via time-series matching between vehicle-mounted camera and spatial information data base

KOJIRO TAKEYAMA<sup>1</sup> TAKEO KATO<sup>1</sup> KUNIHIRO GOTO<sup>1</sup>

#### 1. はじめに

自動運転システムでは、道路や地物などの空間情報を有する地図 DB において自車位置推定を行うことで、周囲の物体との位置関係を把握し障害物と衝突することなく目的地へと向かうことができる。このため、自動運転システムの信頼性を担保するためには、地図上の自車位置を高精度に推定する技術が重要となる。自動運転では誤差 0.1~0.3m 程度の位置精度を常に維持する必要があるため、多くの場合は高性能な車載 LiDAR(レーザ測距計)を用いた位置推定手法が用いられる。この方法では LiDAR 計測した車両周囲の立体物形状と地図 DB 内の立体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[1][2]であるが、現状ではコストの高さが課題となる。そこで、本研究では市販車両に搭載可能な安価なセンサ構成を用いて、あらゆる環境で誤差 0.3m 内の位置推定を目指す。

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特徴と、地図 DB 中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(図 1)。照合の手がかりとして利用できる特徴は多様であるが、大きく 2つのアプローチに分類できる。一つ目は、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]である。この方法では、各オブジェクトの 3次元位置を地図 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。オブジェクトは日照条件の変化や経年変化が生じた場合でも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事前に地図 DB に登録したオブジェクトが存在しない場所も多いため利用シーンは限定される。

一方、二つ目の方法として、特徴点を手がかりとした自車位置推定手法が挙げられる[4]。特徴点はオブジェクトよりもミクロな特徴であり、一般的には立体物の角やポール先などコーナー特徴と呼ばれる箇所に自動的に割り当てられる。特徴点は走行シーンのあらゆる物体上に存在する可能性があるため、特定の物体を指定するオブジェクトベースの方法に比べて利用シーンは大幅に増加する(図 2)。一方、特徴点はオブジェクトに比べて日照条件や経年変化などによる物体の見え方に影響を受けやすいため、地図 DB と車載カメラ画像中の特徴点の照合をうまく行えない恐れがある。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、残りの正しく照合できた特徴点の数が少ない場合には位置推定精度の安定性が低下する。

そこで、本研究では特徴点を用いた位置推定手法のロバスト性を向上することで、あらゆる環境で高精度な位置推定を提案した。提案手法では車載カメラ画像の時系列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することを基本アプローチとする。これに

<sup>1</sup> 株式会社 豊田中央研究所

より、照明変化などにより特徴点の正しい照合が困難なシーンや、そもそも周囲に特徴物が少なく照合の手がかりとなる特徴点が得られにくいシーンなどにおいても精度良い自車位置推定が可能となる。また、元々十分な数の特徴点を照合できるシーンにおいては、地図 DB に保存する特徴点の密度を減らしても十分な位置精度が得られるようになるため、地図 DB に要する膨大な保存容量を低減できるメリットもある。

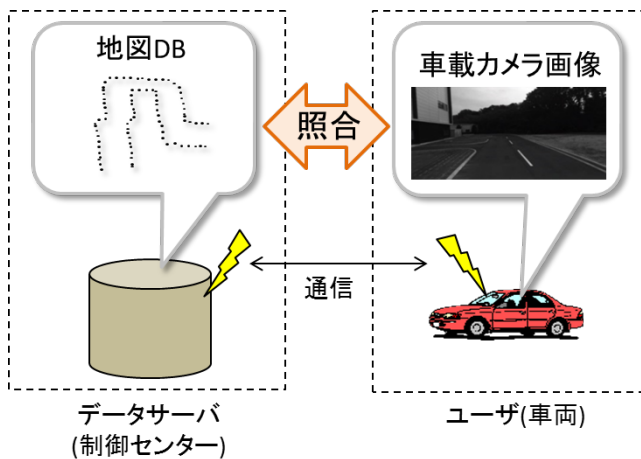


図1 カメラ画像と地図 DB を用いた位置照合システムイメージ




図2 オブジェクトベースと特徴点ベースの違い

## 2. 従来手法

以下では従来手法として、特徴点を利用した位置推定の基本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3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だまかに分かれば良いため、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[5]や

AKAZE[6]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、対応する特徴点同士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。

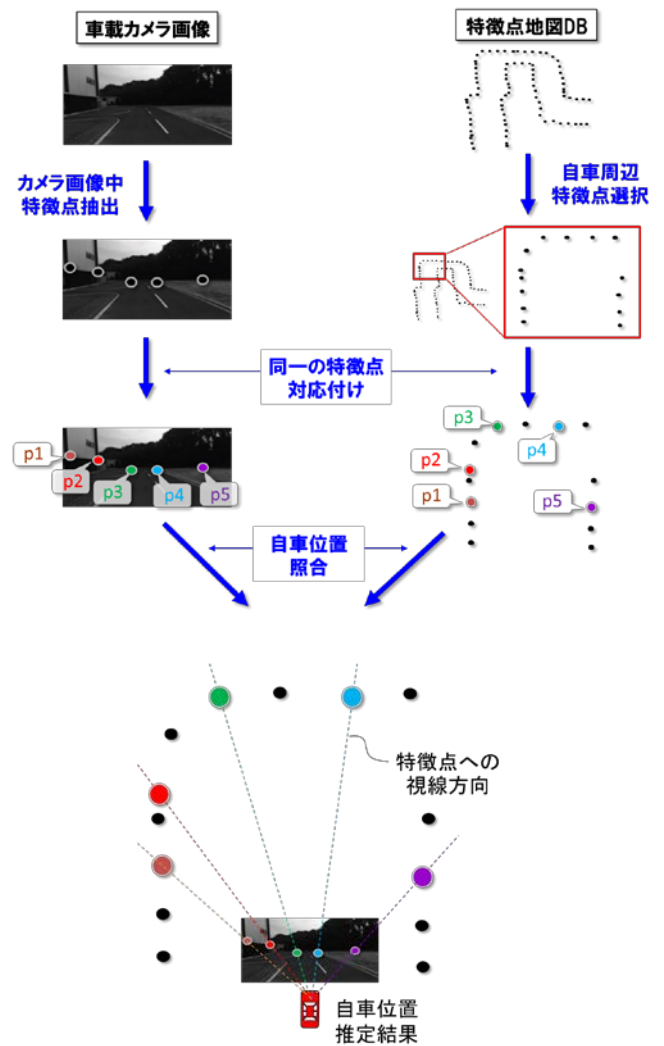


図3 特徴点を用いた位置推定の基本的な流れ

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。

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

ただし,

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

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),  $\phi$  は自車の姿勢 (ピッチ  $\phi$ , ヨー  $\theta$ , ロール  $\psi$ ) を要素とした 3 次元回転行列 (未知数),  $\mathbf{x}$  は 3 次元自車位置 (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  $3 \times 3$  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 [7] などを用いた収束演算により最適解の探索を行う。

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

( $N$  は推定に用いる特徴点数)

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 4) では位置推定の精度が劣化する恐れがある。



(a) 特徴が少ないシーン (b) 照明条件変化シーン  
図 4 特徴点の照合が困難なシーン

### 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することを基本コンセプトとする。図 5 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

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伴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。

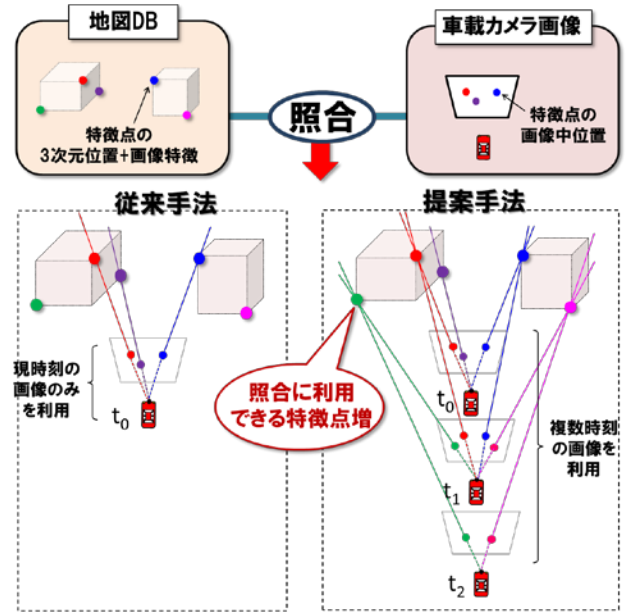


図 5 提案手法の基本コンセプト

以下に具体的な自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。

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

ただし,

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

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,  $\mathbf{R}_t$  は時系列の自車姿勢 (ピッチ  $\phi_t$ , ヨー  $\theta_t$ , ロール  $\psi_t$ ) 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  $3 \times 3$  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伴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,

$$\Delta \mathbf{x}_t = \begin{bmatrix} \sum_{n=1}^t V_{n1} \cos(\theta_0' - \Delta t \sum_{i=2=1}^i \omega_{i2}) \\ \sum_{n=1}^t V_{n1} \sin(\theta_0' - \Delta t \sum_{i=2=1}^i \omega_{i2}) \\ \sum_{n=1}^t V_{n1} \sin(\phi_1') \end{bmatrix}, \quad \theta_0' = \theta_1' + \omega_1 \Delta t$$

$$\begin{bmatrix} \phi_t \\ \theta_t \\ \psi_t \end{bmatrix} = \begin{bmatrix} \phi_0 \\ \theta_0 - \Delta t \sum_{i=1}^t \omega_{i1} \\ \psi_0 \end{bmatrix} \quad (5)$$

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,  $\omega_t$  はジャイロのヨーレート,  $\phi_1'$ ,  $\theta_1'$  はそれぞれ前タイムステップにおける  $\phi_0$  (ピッチ),  $\theta_0$  (ヨー)の推定結果であり,  $\theta_0'$  は  $\theta_1'$  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, その他は全て既知の値である。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,  $\phi_0, \theta_0, \psi_0$  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  $\phi_0, \theta_0, \psi_0$  であり, その他は全て既知の値である。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  $\phi_t, \theta_t, \psi_t$  が 1 つの固定された未知数の組

$\phi_0, \theta_0, \psi_0$  に置き換えられたことを示す。

以上に挙げた式(4), 式(5)を式(3)に代入することで, 時系列データ数と同数ある未知数  $\mathbf{x}_t$ ,  $\phi_t$ ,  $\theta_t$ ,  $\psi_t$  をそ 4 つの未知数  $\mathbf{x}_0$ ,  $\phi_0$ ,  $\theta_0$ ,  $\psi_0$  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伴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。

提案手法では従来手法と同様に最小二乗法を用いて  $\mathbf{x}_0$ ,  $\phi_0$ ,  $\theta_0$ ,  $\psi_0$  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  $\mathbf{x}_0$ ,  $\phi_0$ ,  $\theta_0$ ,  $\psi_0$  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[8], 高精度位置計測装置 POSLV[9]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 6 に特徴点 3 次元位置の算出手順を示す。まず AKAZE[6]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転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方向の位置(自転車-特徴点間の距離)を取得する。これにより, 自転車と特徴点の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 を用いて自転車の絶対位置・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[10][11]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。

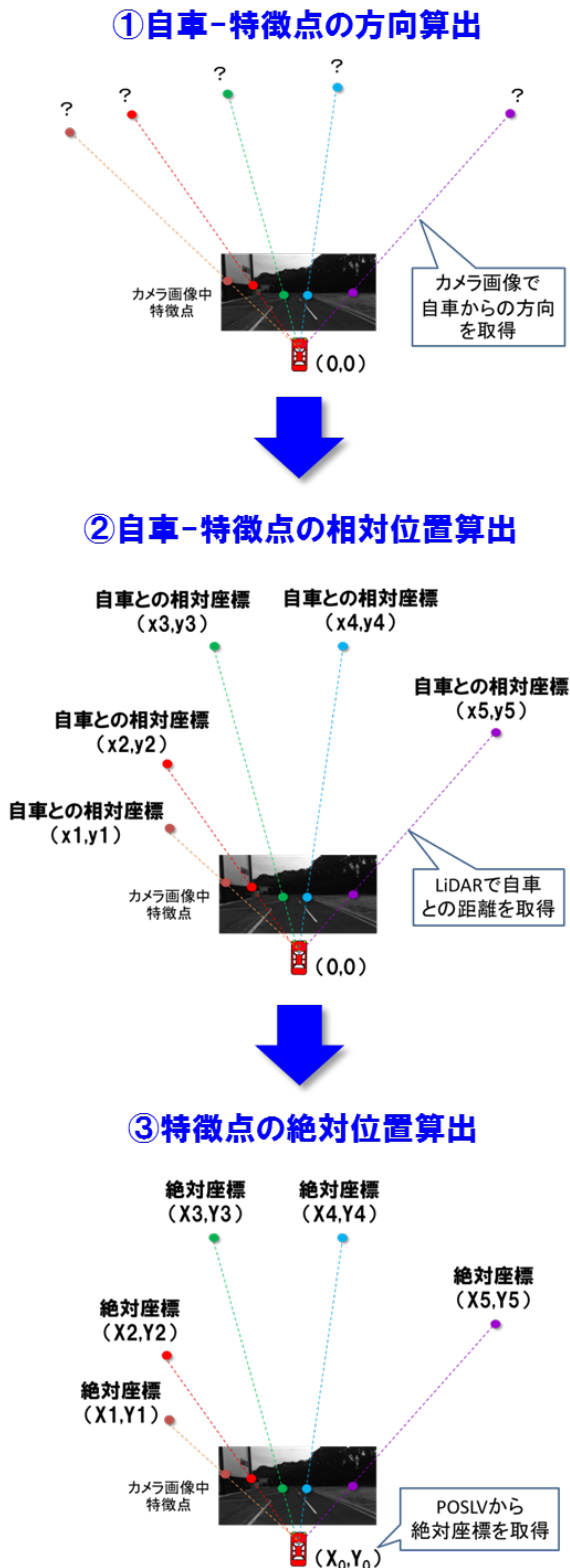


図 6 特徴点地図 DB の生成方法

## 5. 実験

### 5.1 実験条件

提案手法の効果を確認するため、実車を用いた走行実験を行った。以下に、実験に使用した機器、評価コースおよび評価方法について述べる。

#### 【実験機器】

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 7)。また、ジャイロ、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、自転車位置のリファレンスは POSLV[9]を用いた。また、特徴点地図 DB は 4 章に記した方法にて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 : 66.6ms, POSLV : 10ms, 車輪速・ジャイロ : 12ms であり、全てを 66.6ms で同期して評価を行った。



図 7 車載カメラ画像

#### 【評価コース】

図 8 に示す走行路にて位置推定の精度検証を行った。コース周囲には建物が存在し、比較的多くの特徴点を照合できる環境である。一方、本研究では照合できた特徴点が減少した時における提案手法の効果を定量的に把握するため、照合できた特徴点の数を意図的に間引く処理を行い、特徴点の照合が困難な環境を模擬した。以下に評価方法を示す。




図 8 評価コース

#### 【評価方法】

本評価では特徴点の照合が困難な環境を模擬するため、各時刻において画像-地図 DB 間で照合できた特徴点数を N まで減らした場合における提案手法の効果を評価した。図

9に元データと模擬環境におけるNを示す。元データでは走行コース中でN=150~350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毎に照合できた特徴点をランダムに削除し、それぞれN=100, 50, 20, 10個まで一律に減らしたパターンを生成した。図10に模擬環境における特徴点照合の例を示す。図中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、赤の点はその中でカメラ画像中の特徴点と照合できたものを示す。元データでは照合できた特徴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見られる。

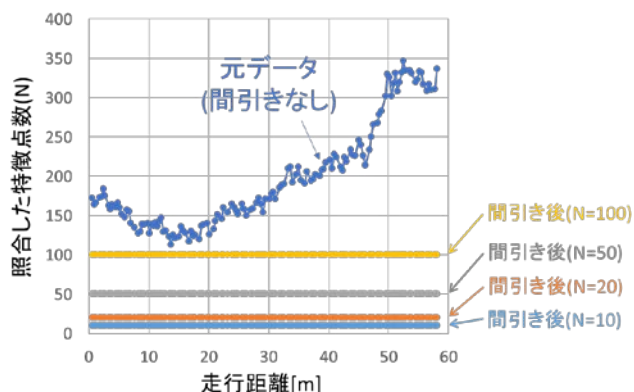


図9 模擬評価のため生成した特徴点数Nのパターン




図10 照合できた特徴点数Nの変化の様子

## 5.2 実験結果

ここでは、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）の比較を行った結果を示す。図11

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の減少に伴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の減少に伴う誤差のばらつき度が軽減されていることが分かる。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増加するため、誤差の低減効果が得られていると考えられる。

コース全体の中で、位置誤差が所定の値以下であった場所の割合(場所率)を図12に示す。ここでは、自動運転を行うために必要な最低限の精度(誤差0.3m)と、安全性と快適性を保証できる精度(誤差0.1m)についての場所率を評価した。誤差0.3m内の場所率(a)について、従来手法ではN $\geq$ 20では場所率が99%~98%で推移し、N=10では場所率が87%程度まで低下していることが分かる。一方、提案手法では場所率が全体的に底上げされており、N $\geq$ 20では100%、N=10の場合においても95%以上を維持しており、Nの減少に伴う場所率の低下度合いが改善されている。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内の位置推定が可能であることを確認した。また、誤差0.1m内の場所率(b)について、従来手法ではNの減少に伴い88%~36%で推移しているのに対し、提案手法では92%~60%となっており、最大24ポイントの改善幅が見られた。このことから、提案手法を用いることで誤差0.1mの位置推定の実現についても大きく寄与できることを確認した。

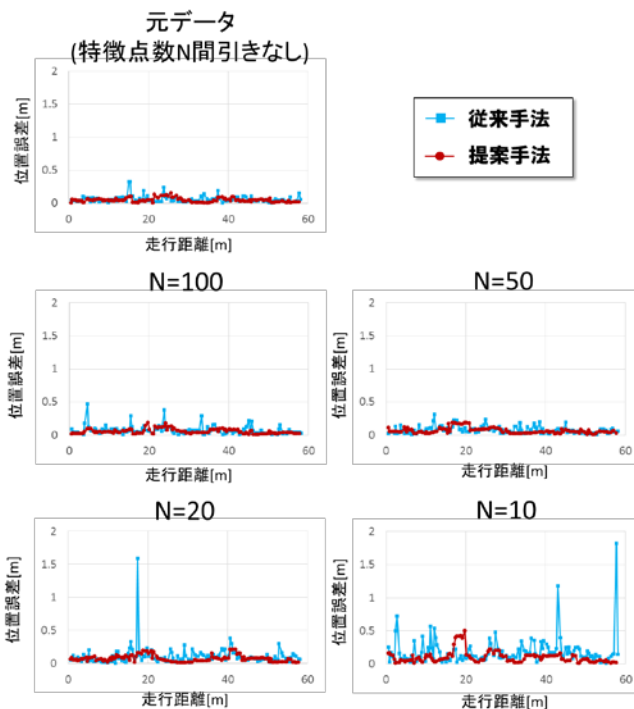




図11 位置推定誤差



(a) 位置誤差 0.3m 以下を満たす場所の割合



(b) 位置誤差 0.1m 以下を満たす場所の割合

図 12 所定の位置精度(0.3m, 0.1m)を満たす場所の割合

## 6. まとめ

本研究では、どのような環境でも高精度(誤差 0.3m 以下)かつ安価な自動運転用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とジャイロ・車輪速の観測値を統合することで、複数時刻の特徴点を同時に照合に利用することが可能となった。これにより照合できる特徴点数が一時的に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。実験では実走行データを用いて、照合できる特徴の数と位置精度の関係を検証した結果、照合できる特徴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。最も劣悪な環境

において位置誤差 0.3m 以下を達成できる場所の割合は従来手法の 86.8%から 95.6%へと向上し、提案手法の実用性の高さを確認することができた。

提案手法を用いることで、あらゆる環境における安定的な位置精度確保に寄与すると同時に、地図 DB 中の特徴点の密度を一定程度まで落としても十分な位置精度を確保できるようになるため、地図 DB のデータ量削減への寄与も期待される。

## 参考文献

- [1] R.W.Wolcott, R.M.Eustice, “Fast LIDAR localization using multiresolution Gaussian mixture maps”, In Proc. International Conference on Robotics and Automation (ICRA), 2015
- [2] I.Baldwin, P.Newman, “Road vehicle localization with 2D push-broom LIDAR and 3D priors”, In Proc. International Conference on Robotics and Automation (ICRA), 2012
- [3] M.Schreiber, C.Knoppel, U.Franke, “LaneLoc: Lane marking based localization using highly accurate maps”, In Proc. IEEE Intelligent Vehicles Symposium (IV), 2013.
- [4] 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.1.92(8), pp.1440-1451, 2009
- [5] D.G.Lowe, “Distinctive image features from scale-invariant key points”, International Journal of Computer Vision, Vol.60, Issue. 2, pp.91-110, 2004
- [6] P.F.Alcantarilla, “Fast explicit diffusion for accelerated features in nonlinear scale spaces”, in Proc. British Machine Vision Conference (BMVC), 2013.
- [7] D.Marquardt, “An algorithm for least-squares estimation of nonlinear parameters”, SIAM Journal on Applied Mathematics, vol.2, pp.431-441, 1963.
- [8] “Velodyne LiDAR”, <http://velodynelidar.com/hdl-64e.html> (2017/10/6)
- [9] “POSLV Specifications”, [https://www.applanix.com/pdf/POSLV\\_Specifications\\_oct\\_2016\\_yw\\_\(1\).pdf](https://www.applanix.com/pdf/POSLV_Specifications_oct_2016_yw_(1).pdf) (2017/10/6)
- [10] B.Liu, M.Yu, D.Maier, R.Männer, “An Efficient and Accurate Method for 3D-Point Reconstruction from Multiple Views”, International Journal of Computer Vision, Vol.65, Issue.3, pp.175-188, 2005
- [11] S.Agarwal, N.Snavely, I.Simon, S.M.Seitz and R.Szeliski, “Building rome in a day”, In Proc. International Conference on Computer Vision (ICCV), 2009

## 著者紹介



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 など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**（正会員）

豊田中央研究所

1990年名古屋大学工学部卒業，1992年名古屋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**（正会員）

豊田中央研究所

2001年岐阜大学工学部卒業，2003年同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。