3次元高精細点群データを活用した 多層マップマッチングによる公道自己位置推定*

米陀佳祐** 三田誠一*** 奥谷 翼† 武藤健二†

Urban Road Localization by using Multiple Layer Matching and High Resolution 3D Point Cloud

Keisuke YONEDA, Seiichi MITA, Tsubasa OKUYA and Kenji MUTO

In recent years, automated vehicle researches move on to the next stage, that is, auto-driving experiments on public roads. To realize practical performance, some static information should be kept on memory such as road topology, building shape, white line and so on. Some measurement companies have already begun to provide highly-precise 3-D point cloud. This study focuses on how to realize accurate localization based on the use of LIDAR data with precise map. In different roads such as urban road and expressway, the observation information of surrounding roads is significantly different. For example, on the urban road, many buildings can be observed at the upper part of the vehicle. Such observation enables to realize accurate map matching. On the other hand, in the expressway, the upper part of the vehicle has no specific observations. Therefore, it is necessary to observe the lower part of such area for the map matching. To adapt to the situation changes, we propose a localization method which is based on multi-layered scan matching. The main idea is to effectively use the features observed in different heights. Localization experiments show that the proposed method is able to estimate accurate vehicle position in different driving areas.

Key words: automated vehicle, self-localization, point cloud, map matching, iterative closest point, normal distribution transformation

1. 序 論

近年、高度道路交通システムの技術は様々な研究機関や企業において非常に注目されており、その応用として自動運転の研究開発が進められている。自動運転を実現するための要素技術としては、走行中の周辺環境を認識するための技術及び車両を安全で滑らかに制御するための技術に分類される。前者の環境認識としては現在の車両位置を高精度に推定する技術と他車や歩行者及び信号機などの周辺物体の状態を識別する技術が大きな課題として挙げられる。これらの課題として、複雑な環境における安定な性能の実現があり、欧米をはじめとして公道での実証実験が進められている^{1)~4)}。本研究では、自動運転の技術における車両の自己位置推定に焦点を当てる。

車両の位置・姿勢をロバストに推定するための代表的な技術として、SLAM(Simultaneously Localization And Mapping)という技術がある。SLAM技術では、自車両が観測した情報に基づいて環境地図を構築しながら相対的な位置を推定する。この場合、高精度な地図を作成することにより高精度な位置推定が実現される。SLAM技術は限定された走行環境内での状態推定に有効であるため、自動運転だけでなく自律ロボットの自己位置推定に活用されている^{5)~8)}。しかしながら、公道での走行など広範囲での応用を想定する場合や絶対的な車両位置の精度を推定する場合は適用が困難となる。そこで、高精度な緯度経度の特徴量から構成される地図を活用した自己位置推定の研究が行われている⁹⁾¹⁰⁾¹⁶⁾。

Fig.1 3D LIDAR Scan Points

環境地図を用いた研究としては、道路上の白線やレーンマーク、電柱などの特徴物を地図として与えた位置推定の手法が提案されている⁹⁾¹⁰⁾。しかし、幅広い種類の道路状況においてこれらの特徴量が必ずしも存在するとは言えず、地図を構成する大規模データから自動運転に必要な観測対象の見極めが重要な課題である。さらに、公道走行では建物の高さなど周辺環境によって自己位置推定に適した観測範囲が変化する。

環境地図を活用した自己位置推定では、赤外線レーザの測距センサであるLIDAR (Light Detection And Ranging)を用いたスキャンマッチングも行われている。代表的な手法としてはICP(Iterative Closest Point)アルゴリズム^{11)~13)}やNDT(Normal Distribution Transformation)アルゴリズム¹⁴⁾¹⁵⁾などが提案されている。この方法では入力点群同士を対応付けしながら誤差を最小化するマッチング行列を探索する。

本研究ではこれまでに、高精細な3次元点群と3次元LIDARセンサ(図1)を用いたICPアルゴリズムによる自己位置推定方法を提案している¹⁶⁾。走行状況に応じて位置推定に有効な観測点群評価・抽出することで、低速走行の静的環境において平均精度0.3m程度の位置推定を実現した。しかしながら、3次元点群同士のマッチングでは観測が疎となる軸方向に関して

* 原稿受付 平成27年2月18日

掲載決定 平成27年7月30日

** 正会員 豊田工業大学(愛知県名古屋市天白区久方2-12-1)

*** 豊田工業大学

† 株式会社デンソー

Fig.2 Experimental Vehicle

点群間の誤対応の発生が起こりやすいため瞬間的に推定誤差が増大する問題が確認された。従って、3次元の点群を直接使用した位置推定ではなく、周囲の状況に応じてマッチングに有効な領域を適切に重み付けすることが重要である。自動運転への応用を見据えた公道の自己位置推定では、以下の課題への取り組みが必要である。

1. 安定した位置推定に必要な観測対象の特定
2. 車両横方向に関して白線幅程度の推定誤差の維持
3. リアルタイムに処理可能な手法の実現
4. 安価なセンサによる位置推定の実現

また、位置及び姿勢角を得る方法として GNSS/INS(Global Navigation Satellite System/Inertial Navigation System) を活用したアプローチもある。しかし、センチメートル単位の精度を得るには十分な衛星の観測が必要であり、遮蔽物の多い市街地では課題が残る。本論文では、市街地自己位置推定のアプローチの一つとして、複数の2次元 LIDAR による観測を想定した多層マップマッチングによる自己位置推定の手法を提案する。提案手法では多数の平面マッチングを独立に実施しマッチング結果に重み付けを行う。重み付けされた各推定結果によって誤対応が発生しやすい状況でもロバストな位置推定を実現する。

以降、第2章では本研究で使用する実験車両及び地図データの概要を述べる。第3章では提案アルゴリズムの自己位置推定アルゴリズムを説明し、第4章で公道走行データに対する評価結果を示す。最後に第5章で結論及び今後の課題をまとめる。

2. 実験車両と地図データ

本研究で使用する実験車両を図2に示す。この車両は、走行中の周辺情報を観測するレーザスキャナ及び高精度 GNSS/INS などのセンサを搭載している。車両上部には3次元 LIDAR である Velodyne 社製 HDL-32E を搭載しており、周辺の物体までの距離を約 10 Hz で計測可能である。実験車両での Velodyne センサの設置位置を図3に、観測情報の例を図1に示す。このセンサは、32層のレーザスキャナが回転しながら360度の各方向の距離を計測し、周囲を3次元的に観測可能である。図3に示すように地面から2.4 mの高さにセンサを設置しており、上方向 10 deg、下方向 30 deg の範囲を最長 100 m でスキャン可能である。回転方向の角度分解能は約 0.18 deg であり、一回転の観測で約 62,000 点の点群が得られる。図1中の観測点の色がレーザスキャナの各層を表す。また、高精度 GNSS/INS として Appalanix 社製 POS/LV610 を搭載し、車両の位置(緯度・経度)、姿勢角、速度及び加速度の情報を 200 Hz で取得可能

Fig.3 Sensor Setting for Experimental Vehicle

(a) 3D Point Cloud

(b) Ground Surface Point Cloud

Fig.4 MMS Point Cloud Map for the Campus Area

である。さらに、固定基地局情報を活用した RTK-GNSS (Real Time Kinematic GNSS) を利用することで最小誤差 0.02 m の精度の位置情報が得られる。GNSS の測位では観測する衛星状態に応じて得られる位置精度が変化するが、本センサでは定量的な位置精度をセンサ内で算出し記録可能である。このほかに車両の CAN(Controller Area Network) 情報として取得可能な車速及びヨーレートを記録する。この車速及びヨーレートは車載ネットワーク内で共有されている車両情報であるため、車両から得られる安価なセンサ情報として活用する。

次に、実験車両の絶対的な現在位置を推定するための高精度地図を与える。この環境地図は、複数のレーザスキャナ及び高精度 GNSS/INS を有する計測車両である MMS(Mobile Mapping System) が計測した 3次元点群データから構成される¹⁷⁾¹⁸⁾。MMS による計測では 0.1 m 以下の絶対的な精度を持つ位置情報を記録可能であり、図4のように高密度な3次元点群として環境地図を作成可能である。以上より、3次元 LIDAR により観測した情報と MMS による地図情報から現在位置を推定し、得られた位置情報を実験車両の高精度 GNSS/INS と比較して性能評価を行う。

位置推定に当たり車両のローカル座標系及びグローバル座標系を定義する。ローカル座標系は車両に設置した GNSS/INS のアンテナから垂直に下方向の地面へ投影した位置を原点とし、車両前方を X_L 、左方向を Y_L 、上方向を Z_L とし、それぞれの右手方向にロール、ピッチ及びヨーとする(図1)。また、グローバル座標系では、緯度及び経度を国土交通省で定義された平面直角座標系¹⁹⁾に変換した基準点を原点とし、北方向を X_G 、西方向を Y_G 及び高度 Z_G とする。なお、図3における LIDAR センサから車両座標系への座標変換の情報は既知であることを前提とする。

Fig.5 Flow-chart of Proposed Localization Method

3. 提案自己位置推定手法

3.1 自己位置推定の概要

LIDAR による観測点群と 3 次元地図点群を対応付ける自己位置推定では、以下に示すセンサの観測方式に関する問題及び公道の走行環境に関する問題の考慮が必要である。

- 一般的に LIDAR センサは回転しながら周辺の距離を計測する。平面方向に密な計測が可能であるが、その平面の法線方向には疎な計測となる。
- 公道における走行環境では、高さの異なる建物が分布し、周辺車両・歩行者などの動的物体が位置するため、走行路ごとにマッチングに適した観測高さが変化する。

本論文で提案する自己位置推定法を図 5 に示す。提案手法では車両のグローバル位置 x_t, y_t, z_t 、ヨー角 θ_t 及びピッチ角 ϕ_t の 5 軸の姿勢を推定する。ロール方向の変化は微小と仮定して本論文では推定しない。3 次元 LIDAR による観測では高密度な環境地図に対して疎であるため誤対応の原因となる。提案手法では、観測点群を Z_L 軸方向に対して多数の層に分割し、2 次元のマッチングに制限することでこの問題を回避する。また、各層ごとに独立にマッチングを行うことで、周辺の車両や歩行者及び建物の変化などの影響が発生する場合においてもマッチングに適した観測の利用が可能となる。本手法では観測情報として 3 次元 LIDAR の観測点及び車両の CAN 情報から取得できる車速及びヨーレートの情報を与え、以下の手順に従い環境地図とのマッチングを行う。

1. 初期位置の車両状態として高精度 GNSS/INS の位置・姿勢角を表す行列 M_t^{LtoG} を与える (初回のみ)。
2. 車速・ヨーレートをオドメトリとして座標変換行列 ΔM_t を計算する。
3. $\Delta M_t, \Delta M_{t-1}, \dots, \Delta M_{t-(m-1)}$ を用いて直近 m フレームの観測点群を重ね合わせて静止物体の点群を抽出する (詳細は 3.2 節)。
4. 3. で得た静止点群を、車両座標系 Z_L 軸方向に Δh m ごとに分割して多層の点群とする (詳細は 3.3 節)。
5. 前フレームの推定位置及びオドメトリからグローバル位置を与える。グローバル位置を基準に環境地図点群から周辺の点群を抽出し、ローカル座標系に変換する。
6. 観測点群及び環境地図から平面推定により地面の高さ及

Fig.6 Static Point Extraction

び傾斜角を計算する。各推定平面から Z_L 軸方向及びピッチ角の偏差を計算して予測位置の補正用行列 $M_t^{\Delta Z}$ を計算する (詳細は 3.4 節)。

7. 6. による補正後の車両位置を基準に環境地図をローカル座標系に変換する。観測点群の各層ごとに地図点群を割り当て、点群マッチングを実施する (詳細は 3.5 節)。
8. 各層のマッチング結果を統合し、推定位置の変換行列 M_t^E を計算する (詳細は 3.6 節)。
9. 2. から 8. にて得た座標変換行列 $M_t^{LtoG}, \Delta M_t, M_t^{\Delta Z}$ 及び M_t^E から現在位置 P_t を計算する。
10. $\Delta M_t, M_t^{\Delta Z}$ 及び M_t^E を次フレームにフィードバックし、2. へ戻る。

ここで、各座標変換行列を 4×4 の同次座標系行列として与え、以下に定義する。

$$\Delta M_t = \begin{bmatrix} R_z(r_t \Delta t) & T_x(v_t \Delta t) \\ 0 & 1 \end{bmatrix} \quad (1)$$

$$M_t^{LtoG} = \begin{cases} M_t^{GNSS} & t = 0 \\ M_{t-1}^{LtoG} \Delta M_{t-1} M_{t-1}^{\Delta Z} M_{t-1}^E & \text{otherwise} \end{cases} \quad (2)$$

$$P_t = \begin{bmatrix} x_t & y_t & z_t & 1 \end{bmatrix}^T = M_t^{LtoG} \Delta M_t M_t^{\Delta Z} M_t^E \begin{bmatrix} 0 & 0 & 0 & 1 \end{bmatrix}^T \quad (3)$$

ただし、 $R_z(\cdot)$ は Z_L 軸周りの回転行列、 $T_x(\cdot)$ は X_L 軸方向の並進ベクトルである ($T_x(a) = \begin{bmatrix} a & 0 & 0 \end{bmatrix}^T$)。また、 M_t^{GNSS} は高精度 GNSS/INS から得られる位置・姿勢角に基づく同次座標系行列である。

3.2 観測点群の重ね合わせによる静止点群の抽出

LIDAR による観測点群には、路面や建物及び移動物体などの点群から構成される。しかし、地図点群に移動物体は含まれていないため、事前に観測点群から除去する。点群の除去方法としては図 6 に示すように直近 m フレームの点群を重ね合わせ、重複度の低いものを移動物体とする。具体的には、現在位置を中心とした格子グリッドを $X_L - Y_L$ 平面上に定義し、各グリッドに対して観測点が確認されたフレーム数をカウントする。ただし格子グリッドの大きさは d_{grid} とする。このとき、グリッド毎に m フレーム中 m_{static} フレーム以上の観測がある場合は、静止グリッドとする。そして、現在の観測点群から静止グリッドに含まれる点群を静止点群とする。

3.3 3次元 LIDAR の観測を用いた仮想 2次元観測の生成

提案手法では、異なる高さの 2 次元観測を用いてマッチングを実施する。本論文では、3 次元 LIDAR により観測した点群

から事前に設定した総数 n_{layer} 及び層の高さ Δh の情報に基づいて点群を分割し、仮想的に2次元 LIDAR の観測点群を生成する。図7に2次元点群への変換の様子を示す。観測した3次元点群を車両座標系 Z_L 軸方向に対して予め設定した高さ及び Δh に従い点群を抽出する。図7(b)では路面から1.0 mの高さから $\Delta h = 1.5$ mの範囲を用いた例である。周辺の車両や電柱、建物などの点群が抽出された様子が確認できる。ここで得られた点群を車両座標系 $X_L - Y_L$ 平面上に投影して2次元の観測点群を生成する(図7(c))。

3.4 平面抽出によるZ軸・ピッチ角の補正

提案手法では多層マッチングにより車両位置 x_v, y_v 及びヨー角 θ_v の3軸の状態を推定可能である。しかし、これだけでは傾斜の影響などを含む高度及びピッチ角の状態を適切に推定できない。そこで平面マッチングを実施する前に観測地図から現在位置周辺の地面の傾斜及び高さを計算してその誤差を補正する。平面推定による補正の様子を図8に示す。まず、前フレームの推定位置にオドメトリ移動量を考慮した車両の状態を $M_t^{LtoG} \Delta M_t [0 \ 0 \ 0 \ 1]^T$ として計算する。そして環境地図をローカル座標系に変換後、 $X_L - Y_L$ 平面上に半径 r mの点群を抽出する。次に抽出した点群を $X_L - Z_L$ 平面上に投影して車両の真横から見た状態とする(図8下図)。 $X_L - Z_L$ 平面上でRANSAC(RANdom Sample Consensus)の直線推定を行い、環境地図の地面に相当する直線及び傾斜角を算出する。これにより現在位置を基準とした地面との高度偏差 Δz 及びピッチ角偏差 $\Delta \phi$ が得られる。従って、次式に従い現在位置の補正行列 $M_t^{\Delta Z}$ を計算する。

$$M_t^{\Delta Z} = \begin{bmatrix} R_y(\Delta \phi) & T_z(\Delta z) \\ 0 & 1 \end{bmatrix} \quad (4)$$

ただし、 $R_y(\cdot)$ は Y_L 軸周りの回転行列、 $T_z(\cdot)$ は Z_L 軸方向の並進ベクトルである ($T_z(a) = \begin{bmatrix} 0 & 0 & a \end{bmatrix}^T$)。この補正行列によって車両の予測位置が得られる。

3.5 多層平面マッチングによる推定位置の計算

現在の予測位置が得られると、観測点群及び環境地図点群に対してスキャンマッチングを実施する。本稿では代表的なマッチングアルゴリズムであるICP及びNDTアルゴリズムを採用する。既存研究において、ICP及びNDTの性能結果が報告されている²⁰⁾。しかしながら、M. Magnussonらの実験では評価対象の環境として採掘現場を採用しており、観測される点群の分布が公道環境とは大きく異なる。そこで本研究では、提案する多層マッチングに関してICP及びNDTを適用し、走行環境毎に推定位置性能を評価する。

ICPとNDTのアルゴリズムでは、2つの点群を入力し、一方の点群を他方にマッチングするための座標変換行列を最適化する。両者の大きな違いはマッチングにおける点群同士の対応付けの方法である。ICPでは、点群同士を最近傍探索により個別に対応付けし、この平均距離を最小化する座標変換行列を探索する。これに対してNDTは点群同士の直接的な対応付けではなく、一定サイズごとのボクセルを定義し、ボクセル内の点群の分布を与えてマッチングを行う。具体的には事前に地図点群を各ボクセルに割り当て、正規分布として点群の平均位置及び共分散行列を算出する。そして、各ボクセル内に位置する観測点群に対して、事前に算出した分布を元にマッチング誤差を算出して座標変換行列を探索する手法である。NDTはボクセル

Fig.7 2D Virtual Scan Generation

Fig.8 Z-Pitch Matching

内の分布を与えることで法線方向に相当する特徴を考慮可能となるため、構造物のマッチングに有効である。また、観測点群の数を N とする時の計算量は、ICPが $O(N \log N)$ に対してNDTは $O(N)$ となり大規模点群のマッチングではNDTが高速とされる。これらのマッチングアルゴリズムにより点群同士の位置を合わせる座標変換行列が得られる。本手法では、事前に分割した観測点群の各層に対して、車両座標系の $X_L - Y_L$ 平面ごとに2次元マッチングを適用し、第 i 層に対する座標変換行列を M_t^i を得る。また、観測点群と環境地図点群との間の誤差として最近傍点同士の平均距離 e_t^i を定義する。ただし、対応点との距離が d_{max} を超えるペアは対応点から除外する。

3.6 マッチング結果の統合による推定位置の算出

観測点群の各層に対してマッチングが終了すると、各層で得られた変換行列 M_t^i 及びマッチングの平均誤差 e_t^i に基づき、時刻 t の推定行列 M_t^E を与える。2次元のマッチングの場合、 M_t^i は $X_L - Y_L$ 平面上での移動量 $\Delta x_t^i, \Delta y_t^i$ 及び Z_L 軸周りの回転角度 $\Delta \theta_t^i$ から構成される。ここで、各層で得られた $\Delta x_t^i, \Delta y_t^i, \Delta \theta_t^i$ 及び平均誤差 e_t^i から次式で定義するマッチング尤度として尤度 λ_i を算出する。

$$d_i = \sqrt{(\Delta x_t^i)^2 + (\Delta y_t^i)^2} \quad (5)$$

$$\lambda_i = \exp(-\alpha e_t^i) \frac{1}{\sqrt{2\pi}\sigma} \exp(-d_i^2 / (2\sigma^2)) \quad (6)$$

ただし、 α 及び σ は尤度計算における非負のパラメータである。 λ_i では、マッチング誤差が小さく、オドメトリによる予測位置からの距離が近いものを尤もらしい状態として評価する。この λ_i の加重平均としてマッチングによる移動量 $\Delta \bar{x}, \Delta \bar{y}$ 及び回転量 $\Delta \bar{\theta}$ を算出し、以下に従い推定行列 M_t^E を得る。

$$w_t^i = \sum_j \frac{\lambda_i}{\sum_j \lambda_j} \quad (7)$$

$$\Delta \bar{x} = \sum_i w_t^i \Delta x_t^i, \Delta \bar{y} = \sum_i w_t^i \Delta y_t^i, \Delta \bar{\theta} = \sum_i w_t^i \Delta \theta_t^i \quad (8)$$

$$M_t^E = \begin{bmatrix} R_z(\Delta \bar{\theta}) & [\Delta \bar{x}, \Delta \bar{y}, 0]^T \\ 0 & 1 \end{bmatrix} \quad (9)$$

このとき、 w_t^i はマッチングにおける第 i 層の寄与度となるため、走行中の w_t^i を観察することで周辺の観測に対する多層マップマッチングの有効性を評価できる。一般的に、多数の観測から状態を推定するための方法としてパーティクルフィルタやカルマンフィルタを用いた位置推定手法が利用されている。フィルタリング処理によって誤差を最小化したロバストな状態推定が実現できる。本論文では多層に分割した際のマッチングの効果を評価するため、フィルタリング処理は適用せずに単純化した手法で状態を推定する。ここで定義した尤度はこれらのフィルタリング処理にも拡張可能であるので、更なるロバスト性向上のために改善が期待できる。以上より、観測した車速・ヨーレート及び LIDAR 点群と環境地図を用いて座標変換行列 M_t^{LtoG} 、 ΔM_t 、 $M_t^{\Delta Z}$ 及び M_t^E が得られ、車両状態が更新される。

4. 実走行データによる性能評価実験

4.1 実験内容

提案手法の性能を評価するため、実験車両の計測データを用いた自己位置推定実験をオフラインで実施する。ここでは次節で述べる特徴の異なる走行環境を対象として走行データを記録する。本実験では異なるマッチング手法を各環境に対して適用し、下記の点に焦点を当てて提案手法の評価を行う。

1. 3次元マッチングと単層マッチング及び提案手法による数 km の継続した走行での位置推定の評価
2. 3次元マッチングと単層マッチング及び提案手法による処理時間の比較
3. 3次元マッチングと単層マッチング及び提案手法による位置推定結果の精度評価
4. 提案手法における各層の尤度の有効性評価

推定した位置の評価には、各フレームで記録した高精度 GNSS/INS が計測した情報と比較する。ここでは推定位置に対して、正解位置の車両座標系上での横方向誤差 (Lateral Error)、前方方向誤差 (Longitudinal Error)、ヨー角誤差 (Yaw Error) の絶対値を記録して各 RMS(Root Mean Square) 誤差及び最悪値を比較する。

4.2 実験環境

本実験では以下の道路を実験環境として設定する (図 9)。

1. 愛知県天白区の住宅街 (豊田工業大学からほら貝東交差点経由で名古屋市道東海橋線を天白区相川二丁目まで走行)
2. 愛知県天白区の外環道路 (下原交差点から原一丁目交差点経由で黒沢台四丁目交差点まで国道 302 号線を走行)
3. 愛知県内の高速道路 (南知多道路の美浜 IC-豊丘 IC を走行)

各環境の地図点群及びデータ計測の情報を表 1 に示す。本実験では計測したデータは LIDAR の観測にあわせて約 11 Hz の周期で計測しながら走行したデータである。使用している LIDAR は回転しながら計測を行うセンサであるため、車両速度の上昇により 1 フレーム中の車両位置が大きく変化し、観測

(a) Residential Area and National Highway Area

(b) Expressway Area

Fig.9 Experimental Courses

誤差の増大も想定される。また、道路周辺の駐車車両など観測地図には含まれていない点群が観測されることで誤対応が起こりうる。

地図点群の代表的な画像を図 10 に、走行中の代表的な車載画像を図 11 に示す。走行路の違いとしては、住宅街では走行路周辺に多くの建物があるのに対して、外環道路では長距離にわたり防音壁が位置している。高速道路では周辺の建物はほとんど観測できず、樹木やガードレールなどから位置を推定する必要がある。また、走行路の道路方向に対して特徴物の少ない外環道路や高速道路では進行方向に対する位置精度の確保が課

Table1 Point Cloud Map and Driving Data for Experiments

Condition	Area		
	Residential Area	National Highway	Expressway Area
Point Cloud Map			
Number of Points num	1.5×10^7	1.6×10^7	2.9×10^7
Density num/m ³	33.309	43.2561	29.871
Driving Data			
Driving Distance m	1,800	3,600	8,700
Average Speed km/h	28.483	32.388	61.182
Maximum Speed km/h	48.988	59.260	76.540
Frame Rate fps	11.378	11.087	10.854
Number of Frames	3,300	6,300	5,700

Table2 Experimental Conditions

Type	Value
m frames	10
m_{static} frames	5
d_{grid} m	0.25
n_{layer}	3
Δh m	1.5
r m	10.0
Distance threshold of Nearest Neighbor for ICP m	2.0
Voxel size for NDT m	0.3
d_{max} m	2.0
α	20.0
σ	0.2
Distance threshold to terminate Matching m	1.0×10^{-5}
Minimum velocity for valid frame m/s	0.1
Maximum GNSS accuracy for valid frame m	0.1
Maximum Distance Error to terminate experiment m	20.0

Fig.10 Point Cloud Map for Experimental Area

題となる。以上の点から、住宅街の計測データと比べて、外環道路・高速道路の計測データはマッチングの難しいデータと言える。

4.3 実験条件・走行データ

提案手法の実験条件を表2に示す。また、各走行データに対して、観測点群の Z_L 方向のヒストグラムを図12に示す。図12中のグラフは各実験環境から典型的な走行区間を30 sec抽出して作成した。各ヒストグラムでは、0.5 m、1.5 m及び3.0 m付近に異なるピークが確認できる。この各ピークは、縁石・ガードレールなどの道路境界付近の観測、建物・側壁などの観測及び樹木や高い建物の観測等から構成される。このように高

Fig.11 Typical Driving Images

Fig.12 Height Histogram for LIDAR Observation

Fig.13 Obtained RMS Error and Computational Time with different parameters for Residential Driving Data

頻度な観測にはその環境の特徴的な対象物が含まれるため、これらを考慮して層数及び層の高さを決定する。以上より本稿では、観測した3次元LIDARの点群を Z_L 軸方向に対して-0.5~1.0 m(レイヤ1)、1.0~2.5 m(レイヤ2)及び2.5~4.0 m(レイヤ3)と1.5 m毎に3層に分割して位置推定を実施する。マッチングにおける条件としてICPでは観測した各点群から2.0 m以内にある地図点群と対応付けを行う。1フレームに要する時間が約100 msecであることから、その間の車両の移動量は1.0~3.0 m程度である。オドメトリの利用によりある程度の移動量は得られるが、ここで発生しうる誤差をカバーするために2.0 mとした。また、NDTでは点群を0.3 mのボクセルに区切り分布を定義する。これは、地図点群の精度が0.1 m程度であることから、外壁の法線や電柱物体の形状を捉えるために決定した。尤度計算で用いる式(6)のパラメータ α 及び σ は、地図点群の精度と目標精度の白線幅(0.1~0.2 m)から経験的に設定した。

マッチングの収束条件は、探索の繰り返しの際の移動量の閾値として設定する。この収束条件の閾値の設定によりマッチングの精度及び処理時間が変化する。そこで予備実験として異なる閾値による提案手法の性能を評価する。ここでは住宅街の走行データに提案手法(ICPの3層マッチング)を適用し、異なる収束条件に対するRMS誤差(ユークリッド距離)及びフレーム当たりの処理時間を比較する。収束条件は 1.0×10^{-8} mから 1.0×10^0 mまで、指数部の整数を変化させて9通りの条件で評価した。図13に評価結果を示す。図13より、収束条件を大きくするにつれてRMS誤差は増大し、フレーム当たりの処理時間は減少する傾向が確認できる。リアルタイムな位置推定を達成するには、LIDARの観測周期(11 Hz)以内に処理可能な閾値が必要である。そこで、 1.0×10^{-5} mを閾値として設定する。なお、本実験のマッチングでは10~30回程度の繰り返しで収束可能である。

本実験ではDead Reckoning(DR, 車速・ヨーレートによるオドメトリとZ・ピッチ角の補正による位置推定)のほか、異なる条件のマッチングとして以下に示す計8種類の方法にICP及びNDTを適用して性能を比較する。

1. 3次元点群同士のマッチングによる位置推定
2. 単独の層の点群を使用した2次元マッチングによる位置推定(3種類)
3. 提案手法: 複数の層の点群を使用した2次元マッチングによる位置推定(レイヤ1-2, 1-3, 2-3, 1-2-3の4種類)

以降の実験結果では、3次元マッチング、単層マッチング及び多層マッチングの結果に関して比較を行う。提案手法の多層マッチングでは、複数の層のマッチング結果を統合して推定位置を得ることができる。手法ごとの比較から多層マッチングの

Table3 Observed LIDAR Points

	Residential Area	National Highway	Expressway Area
Average Number of Points per Frame $\times 10^3$ num			
3D	17.654	16.222	15.613
Layer1	4.133	3.625	3.945
Layer2	3.740	2.606	3.291
Layer3	3.188	1.917	2.402
Standard Deviation of Number of Points $\times 10^3$ num			
3D	5.949	6.871	8.536
Layer1	1.209	1.368	1.036
Layer2	1.136	1.033	1.766
Layer3	1.293	0.806	1.759
Average Point Density per Frame num/m ³			
3D	18.226	21.602	24.315
Layer1	14.618	14.249	17.992
Layer2	12.297	11.784	16.998
Layer3	12.666	11.471	13.530
Standard Deviation of Point Density num/m ³			
3D	6.524	7.645	12.023
Layer1	3.201	3.900	4.559
Layer2	3.936	2.653	7.858
Layer3	2.482	2.291	7.602
Valid Frame Ratio %	53.697	40.190	45.825

効果を評価するだけでなく、提案手法においてどのレイヤの組み合わせが走行環境に適するのかも評価する。

実験結果の評価において、高精度GNSS/INSの位置情報はデータ計測時の衛星状況及び周辺建物の遮蔽により有効な精度が得られない場合があるため、RTK-GNSSの計測情報のうちRMS位置精度が0.1 m以下のフレーム及び車両走行中(車速が0.1 m/s以上)のフレームを評価対象とする。実験データの全フレームを用いて位置推定実験を実施し、評価対象フレームに対して正解位置からの誤差を評価する。ただし、位置推定の過程において正解位置から直線距離で20 m以上の誤差が発生した場合は、タスク失敗とみなして実験を終了する。

ここで、各実験環境の走行データに対して、マッチングで使用する3次元点群及び各層の2次元点群データの点群数及び密度を表3に示す。表3ではマッチングに使用する点群数及び密度に関してフレームあたりの平均値及び標準偏差をまとめている。また、表3中のValid Frame Ratioが各環境での評価対象フレームの割合である。これより市街地のエリアでは、各層で観測される点群数・密度が近い値となっているが、高速道路のデータでは高い層ほど全体のバラつきが拡大する様子が確認できる。高速道路では外壁やガードレール等の点群が集中する物体だけではなく、樹木などの点群が分散する物体が多く観測されたため、点群の密度が相対的に大きな値となった。このように、走行環境の違いにより観測される点群の特徴が大きく異なるデータである。なお、本実験ではIntel Core i7-3770 (3.4 GHz)を搭載するWindows 7 OSの計算機を使用し、複数レイヤのマッチング処理を行う際はスレッド処理により並列に実施する。

4.4 実験結果: 継続走行でのタスク達成率及び処理時間の評価

実験結果として、各手法のタスク達成率を表4に、処理時間を表5に示す。表4は各走行データごとに実験の終了したときのフレームの割合を表し、表5は1フレーム当たりの処理時間を表している。各手法の項目では、X-3dが3次元マッチング、X-1, X-2, X-3が単層マッチング、X-12, X-13, X-12, X-123が多層マッチングの結果である(X=I: ICP, X=N: NDT)。推定誤差が大きくなると地図点群との対応がとれなくなりマッチング

Table4 Success Rate For Each Driving Area

Method	Success Rate %		
	Residential Area	National Highway Area	Expressway Area
DR	100.0	59.063	11.509
ICP Matching			
I-3d	100.0	100.0	100.0
I-1	100.0	100.0	100.0
I-2	100.0	100.0	2.474
I-3	100.0	100.0	5.474
I-12	100.0	100.0	100.0
I-13	100.0	100.0	32.947
I-23	100.0	100.0	10.491
I-123	100.0	100.0	100.0
NDT Matching			
N-3d	100.0	100.0	18.860
N-1	100.0	100.0	22.140
N-2	100.0	100.0	4.123
N-3	100.0	100.0	6.386
N-12	100.0	100.0	22.579
N-13	100.0	100.0	19.982
N-23	100.0	100.0	14.807
N-123	100.0	100.0	24.246

DR (Dead Reckoning): Z-Pitch Matching + Odometry

X-3d: 3D Matching

X-1: 2D Matching for Layer 1 (Z_L : -0.5~1.0)X-2: 2D Matching for Layer 2 (Z_L : 1.0~2.5)X-3: 2D Matching for Layer 3 (Z_L : 2.5~4.0)

X-abc: Multiple Layer Matching (Combine Layer a, b and c)

そのものが行われなくなる。適切な比較を行うために、表 5 ではタスクを成功した手法のみまとめている。これらの結果から以下の点が確認された。

- 住宅街及び外環道路では、ICP 及び NDT の両手法ともに走行データの終了地点まで到達可能
- 高速道路では、ICP のレイヤ 1 を含む手法の一部でタスクを達成
- 樹木などの不確かな観測対象が混在する環境において NDT のような分布を対応付ける手法は不向き
- 多層マッチングでは 3 次元マッチングに比べて 1/3 程度の時間で処理可能
- ICP と NDT の処理時間は全体的に同等
- 単層及び多層マッチングでは 1 フレーム当たり 100 msec 前後で処理できるためリアルタイムな位置推定に適用可能

高速道路でのデータでは図 11(c) 及び表 3 に示したように車両上方の構造物が少ないため、レイヤ 3 のマッチングでは適切なマッチングが得られずに姿勢角の誤差が増大し失敗する結果が得られた。他の原因としては、進行方向側の誤差が徐々に大きくなり、タスクを失敗した結果も確認している。進行方向の特徴が少ないシーンは外環道路及び高速道路に含まれており、このような状況ではオドメトリによって進行方向の位置を更新し、マッチングで車両横方向の誤差を補正する必要がある。外環道路では一定間隔で交差点などの特徴が変化するエリアがあるためタスク失敗に至る手法は DR のみであったが、高速道路では長距離に渡って特徴が変化しないため多くの手法が失敗したといえる。

一方、高速道路でタスクを成功した手法はガードレールや縁石などの構造物を含むレイヤ 1 を用いたマッチングである。また表 4 より高速道路の走行では路面から 2.5 m 程度の高さの観測が重要となることも読み取れる。これらの道路情報は車両の横方向の誤差を抑えるランドマークとなるため重要な観測対象である。

Table5 Computational Cost For Each Driving Area

Method	Computational Time per Frame msec		
	Residential Area	National Highway Area	Expressway Area
DR	23.595	—	—
ICP Matching			
I-3d	190.499	285.249	218.775
I-1	47.919	101.846	75.643
I-2	39.362	59.739	—
I-3	39.140	51.278	—
I-12	63.415	110.676	92.445
I-13	64.489	110.347	—
I-23	49.067	61.584	—
I-123	67.069	120.983	97.276
NDT Matching			
N-3d	279.669	379.681	—
N-1	52.630	89.904	—
N-2	52.128	71.646	—
N-3	45.968	61.812	—
N-12	65.832	96.958	—
N-13	69.866	102.876	—
N-23	55.708	71.405	—
N-123	76.685	106.634	—

4.5 実験結果：推定位置の精度評価

表 4 にてタスクを成功した各手法に関して、正解位置との RMS 誤差及び最悪誤差を表 6 に示す。表 6 では ICP・NDT の各マッチング手法に対して、評価項目のうち最も評価の高い結果に太字・下線付き、2 番目の結果を太字付きでまとめている。オドメトリのみによる手法(表中 DR)では、車両 CAN 情報から得られる車速・ヨーレートの精度が十分ではないため、車両が走行するにつれて徐々に誤差が増大する結果が得られている。ICP 及び NDT の実験結果に関して以下の点が確認された。

- 住宅街及び外環道路での実験結果では、全体的にレイヤ 2 及び 3 を利用したマッチング手法が良好な精度を記録
- ICP ベースの多層のマッチングでは、他の手法より最悪誤差を低減し、3 次元マッチングと同等の RMS 誤差を記録
- NDT ベースの多層マッチングでは、単独の層で得られる結果の長所を統合した結果を記録
- 市街地の環境では NDT のマッチングが有効であり、郊外の環境では ICP のマッチングが有効
- 全環境を通して比較すると ICP の 3 層の多層マッチングがロバストで良好な精度を記録

市街地及び外環道路では道路周辺に建物や壁などの特徴的な構造物が位置しているため、上方レイヤのマッチングに適していると言える。一方、レイヤ 1 の観測では地図点群とは異なる歩行者・車両などが観測されるため、誤対応が発生するケースが見られた。市街地で得られた 0.1~0.2 m の RMS 推定精度は、一般的な道路の車線幅が約 3.0 m、白線幅が約 0.2 m である点を考慮すると走行中の位置推定として十分有効な精度であると言える。しかし、高速道路での推定精度はまだ十分な結果とは言えず、地図点群によるマッチングに加えて白線や縁石などのランドマークも考慮した手法が必要である。

4.6 実験結果：提案手法の尤度の評価

最後に、提案手法のマッチングにおいて、式 (7) の正規化した尤度 w_i がどのように変化するかを調べる。住宅街の実験結果として I-123 及び N-123 の手法におけるマッチングの尤度 λ_i の変化を図 14 に示す。図 14 は、実験中の各フレームにおける車両の車速・ヨーレート、各レイヤのマッチング尤度の正規化値をまとめている。提案手法ではこの正規化した尤度に基

Table6 Experimental Results For Each Driving Area

Method	Residential Area						National Highway Area						Expressway Area					
	RMS Error			Abs. Max. Error			RMS Error			Abs. Max. Error			RMS Error			Abs. Max. Error		
	Lon. m	Lat. m	Yaw deg	Lon. m	Lat. m	Yaw deg	Lon. m	Lat. m	Yaw deg	Lon. m	Lat. m	Yaw deg	Lon. m	Lat. m	Yaw deg	Lon. m	Lat. m	Yaw deg
DR	3.689	6.955	1.300	7.677	9.408	3.744	—	—	—	—	—	—	—	—	—	—	—	—
ICP Matching																		
I-3d	0.122	0.132	0.273	0.446	0.636	1.189	0.167	0.242	0.289	1.002	0.759	0.767	1.212	0.337	0.347	5.173	1.832	1.505
I-1	0.204	0.160	0.413	0.871	0.796	1.997	4.478	0.325	0.644	18.61	1.896	7.093	2.225	0.174	0.436	9.397	0.780	2.756
I-2	0.139	0.219	0.389	0.491	0.957	1.810	0.199	0.190	0.336	0.815	0.678	1.036	—	—	—	—	—	—
I-3	0.154	0.243	0.420	0.668	0.862	1.914	0.216	0.186	0.310	0.989	0.598	0.973	—	—	—	—	—	—
I-12	0.136	0.165	0.358	0.427	0.454	1.158	0.296	0.194	0.324	1.302	0.743	1.135	1.249	0.368	0.460	4.913	2.683	2.955
I-13	0.132	0.191	0.304	0.485	0.515	1.131	0.314	0.187	0.318	1.278	0.635	0.915	—	—	—	—	—	—
I-23	0.131	0.203	0.328	0.586	0.863	1.634	0.181	0.183	0.318	0.771	0.614	0.799	—	—	—	—	—	—
I-123	0.124	0.170	0.317	0.434	0.485	1.182	0.242	0.186	0.315	1.304	0.637	0.798	0.972	0.344	0.397	3.584	1.725	2.135
NDT Matching																		
N-3d	6.375	1.042	0.898	11.21	1.971	3.226	0.950	0.226	0.269	4.124	0.741	0.741	—	—	—	—	—	—
N-1	0.437	0.252	0.594	1.643	0.773	2.360	1.461	0.251	0.556	3.516	0.703	2.072	—	—	—	—	—	—
N-2	0.117	0.178	0.300	0.468	0.500	0.827	0.170	0.178	0.253	0.512	0.630	0.787	—	—	—	—	—	—
N-3	0.105	0.189	0.209	0.450	0.681	0.582	0.152	0.176	0.248	0.570	0.567	0.673	—	—	—	—	—	—
N-12	0.296	0.194	0.324	1.302	0.743	1.135	0.170	0.185	0.256	0.571	0.659	0.742	—	—	—	—	—	—
N-13	0.314	0.187	0.318	1.278	0.635	0.915	0.959	0.192	0.345	3.610	0.613	1.022	—	—	—	—	—	—
N-23	0.181	0.183	0.318	0.771	0.614	0.799	0.158	0.178	0.251	0.522	0.617	0.691	—	—	—	—	—	—
N-123	0.108	0.165	0.262	0.406	0.504	0.670	0.164	0.180	0.255	0.567	0.631	0.714	—	—	—	—	—	—

Bold and Underline: Best result

Bold: 2nd Best result

Fig.14 Obtained Likelihood Values for Residential Driving Data

づく加重平均から推定位置を算出している。図 14(b) 及び (c) から、走行によって特定のレイヤの尤度が大きく変化する区間が確認される。この尤度が大きく変化する代表的な区間に関して、図 15 に車載カメラの画像を示す。レイヤ 3 の尤度が極端に小さくなる 100 フレーム目ではマッチングに不適な樹木が確認される。一方、レイヤ 1 及び 2 の尤度が小さくなる 1,900 フレーム目では、交差点付近に多くの停車車両が観測される。これらの観測点群は中央分離帯に対応する地図情報と誤対応を起こしやすくなるため、尤度が小さくなると考えられる。さらに 2,100 フレーム目でも多くの樹木が観測される区間であるためレイヤ 2 及び 3 の尤度が小さくなる傾向が確認された。これらの傾向は、マッチング手法の違いに関わらず同様であることから、周辺の点群分布に応じて適したレイヤの重み付けが実現されていると言える。

Fig.15 Typical Driving Images for Residential Driving Data

5. 結 論

本研究では自動運転の要素技術である自己位置推定技術に関して、ロバストな位置推定を実現するための推定手法を提案し公道の走行データを用いた検証実験から提案手法の有効性を示した。提案手法では観測点群と高精細 3 次元点群を用いた自己位置推定手法として多層マップマッチングによる位置推定を行い以下の点を示した。

- 代表的なマッチング手法である ICP 及び NDT アルゴリズムを道路特徴の異なる公道自己位置推定に適用し各環境での有効性を検証した。
- 多層マップマッチングにより各マッチング結果を統合することで誤対応を防ぎ、平均誤差・最悪誤差を抑制した。

- 多層マッチングにより走行中の周辺環境に適応したマッチングレイヤの重み付けを実現した。

以上より、3次元点群全体を使用するより、多層に分割した手法により精度及び計算時間において有利であることを明確にした。今後は、周辺に特徴物の少ない高速道路において、点群データの分布が大きく変化する状況でのロバストな位置推定の実現が課題である。実験結果よりICPとNDTは、位置推定に適した走行環境に違いがあることが確認されたので、周辺状況に応じて両手法を組み合わせたマッチングを行うことで更なる改善が期待できる。また、十分な精度を維持した位置推定を実現するため、観測した点群によるマッチングだけではなく、電柱などのランドマーク、画像から観測される区画線特徴などを提案手法の枠組みに統合した位置推定の実現を行う。

謝 辞

本論文の実験実施にあたり株式会社アイサンテクノロジーから3次元地図点群データをご提供頂いた。ここに深く御礼申し上げる。

参 考 文 献

- 1) U. Franke, D. Pfeiffer, C. Rabe, C. Knoepfel, M. Enzweiler, F. Stein and R. G. Herrtwich: Making Bertha See, ICCV Workshop on Computer Vision for Autonomous Driving, (2013).
- 2) M. Schreiber, C. Knöppel and U. Franke: LaneLoc: Lane Marking based Localization using Highly Accurate Maps, Proceedings of 2013 IEEE Intelligent Vehicles Symposium, (2013) 449.
- 3) M. Bertozzi, A. Broggi, A. Coati and R. I. Fedriga: A 13,000 km Intercontinental Trip with Driverless Vehicles: The VIAC Experiment, IEEE Intelligent Transportation System Magazine, 5, 1, (2013) 28.
- 4) A. Broggi, P. Cerri, S. Debattisti, M. C. Laghi, P. P. Porta, M. Panciroli and A. Prioletti: PROUD-Public ROad Urban Driverless test: architecture and results, Proceedings of 2014 IEEE Intelligent Vehicles Symposium, (2014) 648.
- 5) C. Urmson, J. Anhalt, D. Bagnell, et. al: Autonomous Driving in Urban Environments: Boss and the Urban Challenge, Journal of Field Robotics, 25, 8, (2008) 425.
- 6) J. Levinson and S. Thrun: Robust Vehicle Localization in Urban Environments Using Probabilistic Maps, 2010 IEEE International Conference on Robotics and Automation, (2010) 4372.
- 7) F. Moosmann and C. Stiller: Velodyne SLAM, 2011 IEEE Intelligent Vehicles Symposium, (2013) 393.
- 8) M. Adams, J. Mullane and B. Vo: Circumventing the Feature Association Problem in SLAM, IEEE Intelligent Transportation Systems Magazine, 5, 3, (2013) 40.
- 9) A. Schlichting and C. Brenner: Localization Using Automotive Laser Scanners and Local Pattern Matching, Proceedings of 2014 IEEE Intelligent Vehicles Symposium, (2014) 414.
- 10) H. Deusch, J. Wiest, S. Reuter, D. Nuss, M. Fritzschke and K. Dietmayer: Multi-Sensor Self-Localization Based on Maximally Stable Extremal Regions, Proceedings of 2014 IEEE Intelligent Vehicles Symposium, (2014) 555.
- 11) P. J. Besl and N. D. McKay: A Method for Registration of 3-D Shapes, IEEE Transactions on Pattern Analysis and Machine Intelligence, 14, 2, (1992) 239.
- 12) 原祥亮, 阪東茂, 坪内孝司, 大島章, 北原格, 亀田能成: 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, 第18回ロボティクスシンポジウム, (2013) 592.
- 13) A. V. Segal, D. Hähnel and S. Thrun: Generalized-ICP, Robotics: Science and Systems (2014).
- 14) P. Biber and W. Strasser: The Normal Distributions Transform: a new approach to laser scan matching, Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems, 3, (2003) 2743.
- 15) C. Ulas and H. Temeltas: 3D Multi-Layered Normal Distribution Transform for Fast and Long Range Scan Matching, Journal of Intelligent and Robotics Systems, 71, 1, (2003) 85.
- 16) K. Yoneda, H. Tehrani, T. Ogawa, N. Hukuyama and S. Mita: Lidar scan feature for localization with highly precise 3-D map, Proceedings of 2014 IEEE Intelligent Vehicles Symposium, (2014) 1345.
- 17) Mitsubishi Electric Corporation: Mobile Mapping System - High-accuracy GPS Mobile Measuring Equipment, <http://www.mitsubishielectric.com/bu/mms/>, (2014).
- 18) AISAN TECHNOLOGY Co. Ltd.: MMS by AISAN TECHNOLOGY, <http://www.whatmms.com/>, (2014).
- 19) 国土交通省 国土地理院: 平面直角座標系, <http://www.gsi.go.jp/LAW/heimencho.html>, (2014).
- 20) M. Magnusson, A. Nüchter, C. Lörken, A. J. Lilienthal and J. Hertzberg: Evaluation of 3D Registration Reliability and Speed - A Comparison of ICP and NDT, Proceedings of 2009 IEEE International Conference on Robotics and Automation, (2009) 3907.