

異なる時空間における3次元点群地図の統合

福富 大輔¹ 前田 一輝^{1,a)} 安積 卓也² 加藤 真平³ 西尾 信彦¹

概要: 自動運転システムは、事前に作成した3次元点群地図(以降、基盤地図)とリアルタイムで取得される点群を用い自己位置推定を行うため、基盤地図上で変化があった場合、その情報を更新する必要がある。本論文では、基盤地図と自動運転車両が作成する3次元点群地図の同一箇所を比較することで、基盤地図の静的情報の更新を行う手法を提案する。GNSSデータと点群の特徴量抽出の併用により2つの地図の同一箇所判定を行い、地図上の路面の点群を利用したクラスタリングやセグメンテーション結果を基に基盤地図を更新する。評価では、地図更新において74%の新規建物の追加、40%の消失建物の除去ができ、基盤地図の更新が可能であることを示した。

キーワード: 自動運転, 3次元点群地図, 分散環境, SLAM, ROS, NDT スキャンマッチング

The Integration of Two Independent Point Cloud Maps Acquired at Different Times

DAISUKE FUKUTOMI¹ KAZUKI MAEDA^{1,a)} TAKUYA AZUMI² SHINPEI KATO³ NOBUHIKO NISHIO¹

Abstract: Autonomous driving can not be operated at a place where there is no point cloud map. When there is a change to static information on a point cloud map, it is necessary to update such as buildings and traffic signals. In this paper, we present updating static map information by integrating the base map and the new map created by the autonomous driving vehicle equipped with cheaper sensors. We propose to make identical point determination of point cloud map by combining GNSS data and feature point extraction of point cloud. Furthermore, difference extraction of a point cloud map is realized by clustering and segmentation taking into consideration the influence of occlusion. Evaluations show that 74% of new buildings were added and 40% of the lost buildings were removed in the new point cloud map by integrating two different point cloud map. This results show the superiority of the proposed method of road surface detection and suppressing the influence of occlusion and that it can realize the integration of two independent point cloud maps acquired at different times.

Keywords: Autonomous driving, point cloud map, distributed computing, SLAM, ROS, NDT

1. はじめに

近年、自動車の自動運転に関する研究が交通事故の削減や無人運転タクシーなどの商用化を目的として盛んである[1]。Waymo社の自動運転システム[2]や、自動運転のオープンソースソフトウェアであるAutoware[3]をはじめとした自動運転システムでは、周辺車両や、道路状況などを把握するために走行経路中のどこにいるかを知る必要があ

る。そのため、Light Detection and Ranging (LiDAR) で取得される Point Cloud(点群)を用いた Simultaneous Localization and Mapping(SLAM) を利用している。LiDARを用いた SLAM は、ビル街やトンネルで精度が低くなる Global Navigation Satellite System (GNSS) や天気に影響されるカメラと異なり、外界環境の影響に強いいため、高精度に自己位置推定できる[4]。LiDARを用いた SLAM では、図1に示すように、事前に生成された点群の3次元地図(3次元点群地図)と、リアルタイムに得られる点群のマッチングを行い自己位置を推定する。そのため、新たな建物が建てられたり、既存の建物が取り壊されたりして3次元点群地図上の静的情報に変化があった場合、自己位置推定の際のマッチング精度の低下に繋がり、自動運転に影響

¹ 立命館大学
Ritsumeikan University

² 埼玉大学
Saitama University

³ 東京大学
The University of Tokyo

^{a)} maep@ubi.cs.ritsume.ac.jp




図 1 LiDAR を用いた自己位置推定

Fig. 1 SLAM with LiDAR.

響を及ぼす。よって、建築物や信号機といった3次元点群地図上の静的情報は更新される必要がある。

既存の研究では、2つの同一箇所の点群データの各対応点の距離を比較する手法[5]を応用し、一定以上の距離がある点を差分とみなしたり、点群データを用いたメッシュデータの構成時に一部分だけを更新したりする手法などが提案されている[6]。しかし、キッチンやテーブルといった屋内の小規模で高密度に点群が取得されているデータや点群への復元時に誤差を含むメッシュデータを対象としており、車両が走行可能な大規模な点群や疎な点群は対象となっていない。

そこで、本研究では、一般的で安価なLiDARを搭載する自動運転車両がSLAMを行い作成可能な3次元点群地図を用いて、測量メーカが作成した基盤となる地図(以降、基盤地図)の静的情報の更新を行う。3次元点群地図の更新のためには、自動運転車両によって作成された3次元点群地図と基盤地図の2つの作成された地図の領域と座標系、時刻が異なるため、地図同士を比較する領域と座標系を合わせる同一箇所判定を行った上で、時刻の異なるデータから差分を抽出する必要がある。提案手法では、GNSSデータと地図を構成する点群の特徴量抽出を併用することで3次元点群地図の同一箇所判定を行い、時刻の異なる3次元点群地図の差分抽出は、精密な路面判定によってオクルージョン^{*1}を考慮した上で、クラスタリングやセグメンテーションを行い物体認識結果を用いて比較することで行う。

評価では、動的な情報を排した特徴量マッチングを行うことで動的な情報を排除しなかった場合と比較して同一箇所判定の精度が約5.45倍向上したことを示した。加えて、差分抽出と統合による地図更新では74%の新規建物の追加、40%の消失建物の除去ができた。これは、提案した路面判定とオクルージョン判定を行わなかった場合と比較してそれぞれ、約1.76倍、2.5倍検出率が向上しており提案手法の有用性を示した。

2. 関連技術・研究

本章では、点群の中から物体を識別するクラスタリングやセグメンテーションの手法と、複数の時間が異なる点群

^{*1} 3次元空間では前後関係があるため、手前にある物体が背後にある物体を隠して見えない状態が発生すること




図 2 路面除去とクラスタリング結果

Fig. 2 Road surface removal and result of clustering.

から表面メッシュを再構成する研究を紹介する。

2.1 点群のクラスタリング・セグメンテーション

Rusuら[7]は各点間のユークリッド距離が一定閾値以下のものを再帰的に同一のクラスとみなしていくことによってクラスタリングをする手法を提案した。Schnabelら[8]は、サンプリングデータからモデルを作成し、そのモデルに最も多くの点を含むようにモデルを再度構築し、モデルが収束するまでサンプリングとモデル作成を繰り返すRandom Sample Consensus (RANSAC)を応用して平面や、球のセグメンテーションを行っている。これらを併用し、Schnabelらの平面検出による路面除去と、Rusuらのクラスタリングを適用したものが図2である。図2は視点を約45度にして見た3次元地図であり、路面部分の点群がなくなり、同じ色の点群が各々一つのクラスを表現している。図2からは、建物などがクラスとして構成されているが、一つの建物などが分離してしまっていることが分かる。

他にも、画像分野で盛んに用いられている輝度差を利用してセグメンテーションを行うFelzenszwalb and Huttenlocher (FH) アルゴリズム[9]を距離画像に直した点群に適用してセグメンテーションを行う手法も存在する[10]。加えて、近年ではディープラーニングを利用した点群のクラスタリング・セグメンテーションの手法も提案[11], [12]されており点群を利用した物体の認識手法は容易に利用できる。

2.2 点群のデータ再構成に関する研究

Martonら[6]は、大規模な点群から作成された表面メッシュモデルを再構成する手法を提案した。この手法は、新たに点群データを取得した際に、表面メッシュを作成した上で、既存の点群の表面メッシュと比較することで更新された部分のみを再構築し、既存のメッシュを更新する。しかし、駐車車両などの動的な物体などは考慮されておらず、表面メッシュからの点群の再構築は誤差が発生するため、自己位置推定に利用する3次元点群地図としての精度を保つことができない。

Hornungら[13]は、八分木に基づいた確率的占有推定を




図 3 提案手法の処理の流れ
Fig. 3 Flow of approach process.

用いた格子地図の作成を行った。これは、地図をグリッドに分割した上で、そのグリッドが点群占有されているか、占有されていないかを表現するものである。Hornung らの手法では、リアルタイムなセンサの視点を利用することで占有された格子の奥にある領域はオクルージョンと判断できる。この手法では、路面の認識ができないことや、センサの視点が必要であることため、既に構成された3次元点群地図同士と比較に利用することが困難である。

3. 提案手法

本章では、取得した場所と時間(時空間)が異なる3次元点群地図を統合するためのアプローチと実装について詳細に述べる。

本研究では、取得した時空間が異なる3次元点群地図を統合することが目標である。そのために、図3で示す流れに沿って同一箇所判定と差分抽出・地図更新の2段階に分けた手法を採用し、3次元点群地図の統合を実現する。図3の各処理の中身については、各節で詳細に説明する。

ここで、基盤地図には Mobile Mapping System(MMS)で作成された高精度な3次元点群地図[14]を利用し、更新のための地図には NDT アルゴリズム (NDT) を用いた SLAM により作成された3次元点群地図を用いるものとする。

3.1 2つの3次元点群地図の同一箇所判定

本節では、図3における、青い点線で囲った部分に該当する、基盤地図と新たに取得した3次元点群地図を比較する際に必要な同一箇所判定の手法について説明する。

まず、GNSS データを用いることで、マッチング範囲の限定を行う。その後、NDT を用いて精密に地図間の同一箇所判定をするために必要な初期の推定座標変換($x, y, z, roll, pitch, yaw$)の算出を行う。この初期の推定座標変換のために、静的な情報のみを用いて特徴量マッチングを行う。このとき、特徴点抽出には uniform sampling を用い、特徴量マッチングには Tombari ら [15] によって提案さ




図 4 路面に対するグリッド作成
Fig. 4 Making grids for road surface.




図 5 路面と非路面の高さ方向に対する点群分布
Fig. 5 Point cloud distribution in height direction.

れた Signatures of Histograms of Orientations (SHOT) 特徴量を利用する。そこで、図3に示すように Preprocessing として地図作成の際に入るノイズ除去と、動的物体の除去をそれぞれの3次元点群地図に対して行った後、特徴量マッチングを行う。

Preprocessing では、路面の高さを推定した後、路面の法線方向から 3m 以下の点群を利用しないことによって、路面と駐車車両や人といった動的物体、動的物体に起因するオクルージョンがほとんど存在しない状態の3次元点群を作成する。図4に示すように3次元点群地図を水平方向に 5m×5m のグリッドに区切った後、各グリッドの路面の高さを推定し、その推定高さから路面の法線方向に 3m 分の点群を利用しないようにする。図5に示すように、高さ推定はセンサからの相対位置として 10cm ごとにヒストグラムを作成し、最も点が多い階級を路面の高さとしてみなす。

3.2 2つの3次元点群地図の差分抽出と地図更新

本節では、図3における、橙色の点線で囲った部分に該当する、基盤地図と新たに取得した3次元点群地図から差分を抽出し統合する手法について説明する。

3.2.1 グリッド分割による詳細な路面判定の実施

2つの3次元点群地図を統合するためには、路面外の物体に対してのみ統合の処理を行う必要がある。そこで、図5に示したように路面の点群は、高さ方向への分散が小さいことを利用して判別を行う。路面の分散の算出は、点群地図を水平方向に 1m×1m のグリッドとして分割し各グリッドに含まれる点群において実施する。

MMS で作成された3次元点群地図と NDT によって作成された3次元点群地図において、それぞれ路面のみを含む点群、駐車車両を含む点群、住宅・街路樹を含む点群、信号機を含む点群における高さ方向への標準偏差を算出した。図6は、MMS と NDT で作成したそれぞれの3次元点群地図の路面における標準偏差の値を4分木で表した




図 6 路面における MMS と NDT 地図の高さ方向へ点群の標準偏差の分布

Fig. 6 Distribution of standard deviation of point cloud about road surface.

表 1 路面以外の MMS と NDT 地図の高さ方向へ点群の標準偏差の平均

Table 1 Average of standard deviation of point cloud about other than road surface.

	車両	住宅・街路樹	高い建物	信号機
MMS [m]	0.340	0.452	1.308	2.072
NDT [m]	0.839	0.494	0.983	2.206

表 2 路面判定結果の組合せによるグリッドへのラベル付

Table 2 Making label for grids using road classification results.

		新地図 路面判定結果	
		True	False
元地図 路面判定結果	True	路面	新規
	False	消失	非路面

ものである。この結果から、路面において標準偏差は 0.06 以下に収まっていることが読み取れる。表 1 は、MMS と NDT で作成したそれぞれの 3 次元点群地図の先程挙げた検証箇所の路面以外について標準偏差の平均を取ったものである。路面以外の物体が存在することによって、路面の標準偏差と比較して明らかに大きくなることが分かる。図 6 と表 1 の結果から、標準偏差が 0.06 以下であるものかつ、100 点以上の点を含むものは路面として判定する。

各グリッドにおいて路面判定の処理を元の 3 次元点群地図と新たに取得した 3 次元点群地図の双方に実施する。その結果に基づき、表 2 のようにグリッドごとに差分候補が含まれる領域(グリッド)の判定を行う。このとき、計測ノイズを除去するため、周囲の 8 つのグリッドが路面と判定されている非路面グリッドを路面グリッドであると判定し直す。2 つの 3 次元点群地図で路面と判定された場合は路面であると確定して差分抽出の対象として扱わない。

3.2.2 動的物体の除去

次に、車両や歩行者といった小さな動的物体の除去の手法を提案する。路面のグリッド判定の結果を用いて 2×2 以下の非路面グリッドかつ路面判定に利用した高さ方向の標準偏差が 1.0 未満であるものを除去する。今手法では、非路面と判定された各グリッドから周辺を探索して各自のグリッドの中で、どの程度のサイズの非路面グリッドの集合に含まれるかを算出する。その上で、2×2 以下の非路面グ




図 7 オクルージョン判定の結果

Fig. 7 Results of occlusion judge.

リッドは削除の候補対象とする。更に、除去する対象を表 1 の結果を元に、その候補に含まれる全ての非路面グリッドの高さ方向の標準偏差が 1.0 未満であるという条件を加える。このことにより、車両や歩行者といった小さな物体のみを除去できる。

3.2.3 オクルージョンが発生している箇所の判定

3 次元点群地図は路面から見て建物の前ある植え込みや駐車車両などによってオクルージョンが発生する。オクルージョンにより一部欠損が起きている 3 次元点群の部分を基盤地図と新たな 3 次元点群地図上で比較した場合、一方にのみオクルージョンが発生していた場合は正確に比較できない。よって、オクルージョンが発生していない部分のみを利用することで差分の比較が容易になる。

本研究では、道路を走行する車両からセンサデータを取得することに着目してオクルージョンの判別を行う。図 7 では、水色で示される建物は LiDAR で取得できる高さよりも十分に高いものであると仮定する。本来路面から取得されるデータは、水色の部分が入るグリッドのみが非路面グリッドであると判別され、それより奥にあるグリッドは空となる。しかし、建築物の前に障害物がある場合、オクルージョンが発生する。オクルージョンが起き一部の点群が欠損しているグリッドを判別するために、路面に隣接しているグリッドか否かを利用する。路面に接するかの探索を行い、路面に接しないグリッドはオクルージョングリッドであると判別する。

3.2.4 静的物体の統合

最後に、2 つの 3 次元点群地図を統合し、一つの 3 次元点群地図を作成する手法について説明する。

まず、静的物体を抽出するため、Rusu ら [7] のユークリッド距離を用いたクラスタリング・セグメンテーションを適用する。適用の際には、非路面グリッドに含まれる点群は全てをクラスタリング・セグメンテーションの適用の対象とし、オクルージョンと判定されたグリッドに含まれる点群は 3m 以上の点群のみを利用する。クラスタ同士の比較と同一性の判別は、クラスタの重心比較あるいは重心と容積の組合せを比較して行う。オクルージョンと判別されたクラスタに関しては、比較した結果の同一性の判定の閾値を緩く設定することで同一性判定を行い、同一であると判断された場合は、基盤地図地図の情報を優先して保存

するものとする。最終的に基盤地図に残ったクラスは消失した対象、新たな3次元点群地図に残ったクラスは追加される対象として、一つの3次元点群地図に統合する。新たな3次元点群地図において路面グリッドと判定されたグリッドは、統合時に路面として処理する。

4. 評価

本章では3章で提案した手法の有用性を検証するため、2つの3次元点群地図の同一箇所判定と2つの3次元点群地図の差分抽出と地図更新についてそれぞれ実際に取得した時間と空間が異なる3次元点群地図を用いて評価を行った。

4.1 評価環境

基盤地図は、測量メカによって作成された高精度なもののかつ点群データが間引かれていないものを利用する。加えて、統合するための情報として、LiDAR(HDL-32e)から得られるデータをNDTによるSLAMを行い、3次元点群地図を作成した。SLAMによる3次元点群地図は0.1cmのボクセルに対して一つの点を持つように平滑化を行ったものを利用した。

2つの3次元点群地図の同一箇所判定の前段階において、統合元の基盤地図はMGRS座標系で保存され、SLAMによって作成された3次元点群地図はlocal座標系で保存されており、取得時間と空間が異なる状態にある。ただし、これらの3次元点群地図は同一箇所判定が可能のように同じ場所のデータを含むものとする。これらのMMSで作成された3次元点群地図とSLAMによって作成された3次元点群地図をそれぞれ20個用意し、同一箇所判定の評価を行った。

2つの3次元点群地図の差分抽出と地図更新では、3次元点群地図の同一箇所判定で高精度に同一箇所であることを判定できた10個の3次元点群地図を用いて評価を行った。統合の対象としてオクルージョン部分については、3m未満の点群は統合の対象とならないことから、以降「建物」と述べた際には2階建て住宅以上の大きさのものとする。基盤地図を一部手作業によって加工し建物を地図から削除し、50の建物と25の電柱・街路樹が統合によって追加されるべき正解データとして評価を行った。同様に、NDTで作成した3次元点群地図を加工し、50の建物と25の電柱・街路樹除去が統合後、除去されるべき正解データとした場合においても評価を行った。

4.2 2つの3次元点群地図の同一箇所判定

本節では、2つの3次元点群地図の同一箇所判定についての評価結果を説明する。

3.1節のヒストグラムを用いた高さ制約の有効性を示すため、高さ制約を行わずに同一箇所を行った場合、高さ制約をSchnabelらの平面検出[8]によって路面の高さを推定




図8 NDT マッチング誤差

Fig. 8 NDT error using.

して行った場合の同一箇所判定の精度と比較する。

4.2.1 ヒストグラムを用いた高さ制約による特徴量マッチングの結果

本項では、ヒストグラムを用いた高さ制約が同一箇所判定において有効であることについて述べる。

図8は、特徴量マッチング後にNDTによる高精度な重ね合わせを20個の3次元点群地図に対して行った際に算出される対応点間の誤差の総和を高さ制約の手法別(None: 平面検出なし, Plane: PCLによる平面検出, Histogram: 提案した路面の高さ方向へのヒストグラム利用)に並べたものである。ただし、斜面などでは平面検出できない場合があるため、成功した場合のみで集計している。

図8が示すとおり、同一箇所判定の精度の差を平均値で比較した場合、ヒストグラムを用いた手法が、平面検出に対して約1.7倍、高さ制約を行わなかった場合に対して約5.45倍の精度が向上することが分かる。

この結果から、3次元点群地図という環境に対して特徴量マッチングを適用する場合、提案手法によるヒストグラムを用いた高さ制約が有用であることがいえる。

4.3 2つの3次元点群地図の差分抽出と地図更新

本節では、2つの3次元点群地図の差分抽出と地図更新について評価結果を説明する。2つの3次元点群地図の差分抽出と地図更新に関して、3次元点群地図の同一箇所判定で高精度に同一箇所であることを判定できた10個の3次元点群地図を用いて、提案手法によって元の3次元点群地図と新たな3次元点群地図の差分抽出を抽出し、新規の建物は3次元点群地図に追加され、消失した建物は3次元点群地図から除去されることを確認する。提案した手法による3次元点群地図の差分抽出と地図更新に加え、路面判定・オクルージョン判定がそれぞれ行わなかった場合にクラスタリング結果のみを用いて3次元点群地図を更新した場合の結果についても評価を行い提案手法の有用性を示す。

4.3.1 路面判定・オクルージョン判定に関する検証

本項では、路面判定・オクルージョン判定について図9に示す一つの3次元点群地図を例に提案手法が適切に行われていることを示す。

図10は、グリッドに分割した上で標準偏差を用いた路

面判定と、計測ノイズの除去により路面を除去した後の処理結果を示している。傾斜がある場合でも、ほぼ全ての路面部分をくり抜くことができていることが確認できる。




図 9 路面・ノイズ除去前の
3次元点群地図例

Fig. 9 Before process of
pointcloud map.




図 10 路面・ノイズ除去後の
3次元点群地図例

Fig. 10 After process of
pointcloud map.

図 11 はオクルージョン判定の結果の例を示している。緑色で示されている部分は、路面に隣接しているオクルージョンが発生していないと判定された部分であり、赤色で示されている部分はオクルージョンが発生していると判定された部分である。その後、オクルージョン部分は近傍の路面高さから 3m 分の点群に関してクラスタリングの対象として外す。図 12 は、図 11 の点群からオクルージョン部分は路面高さから 3m 以上の点群に限定し、クラスタリングの対象となる点群を示したものである。図 12 では、オクルージョンが発生していないとされた緑色部分は全ての点群がそのままクラスタリングの対象となっているが、赤色で示されたオクルージョン部分は路面から 3m 以下がクラスタリング対象から除去されている。




図 11 オクルージョン判定結果
(高さ制限なし)

Fig. 11 Occlusion judge result
without height limit.




図 12 オクルージョン判定結果
(高さ制限あり)

Fig. 12 Occlusion judge result
with height limit.

このように、提案手法によって、正確に路面判定とオクルージョン判定が行われ、クラスタリングに利用される点群が静的物体の中でも、どのような環境で取得した場合でも変化することがないものに限定されることが分かる。

4.3.2 3次元点群地図に対する静的物体の更新

本項では、3次元点群地図から差分クラスタを追加・除去することで3次元点群地図上の静的物体が更新できることを示す。表 3 は、50 の建物と 25 の電柱・街路樹を統合によって追加・除去されるべき正解データとして、差分抽出と更新処理を行った結果を示している。

表 3 3次元点群地図に対する静的物体の追加・除去の正解率

Table 3 Accuracy rate of update for point cloud map.

	追加正解率 [%]	除去正解率 [%]
建物 (2 階建て住宅以上)	74	40
電柱・街路樹	56	52

3次元点群地図に対する静的物体の追加

2 階建て以上の建物については、74%の正解率で追加でき、電柱・街路樹は 56%の正解率で追加できた。電柱・街路樹の正解率が建物と比較して低い理由は、物体が細いため走行時に取得した点群が疎になりやすく、クラスタリング時にクラスタとして認識できなかったことである。また、既存の建物が新たに追加されたことはなかったが、一部既存の電柱・街路樹が新たな3次元点群地図に重複して追加されてしまった。これらは、電柱・街路樹などに特化したクラスタリング・セグメンテーションなどを適用し区別することで解決可能だと考えられる。

3次元点群地図の一例を用いて、一つの建物が追加される様子を説明する。図 13 は、基盤地図であり、図 14 は新たに取得した3次元点群地図である。図 14 のうち、白丸で示した部分が新たな3次元点群地図では増えている。この3次元点群地図同士を統合した結果が、図 15 である。ここでも白丸で示したとおり新たに取得した3次元点群地図から、オクルージョン判定などを行った後にクラスタとして建物が認識されクラスタ部分が追加されていることが分かる。加えて、路面がなかった赤丸で示した部分に対しては、後から取得した路面が適切に統合されていることが分かる。一方、図 14 と図 15 の白丸で囲った建物を比較すると、図 15 の3次元点群地図の建物の一部が欠損していることが分かる。これはクラスタリングによってクラスタとして認識されなかった部分が追加されなかったためであり、クラスタリング性能の改善により地図更新後の情報の精度も上がると考えられる。




図 13 3次元点群地図例 A
Fig. 13 point cloud map 'A'.




図 14 3次元点群地図例 B

Fig. 14 point cloud map 'B'.

3次元点群地図に対する静的物体の除去

2 階建て以上の建物については、40%の正解率で除去でき、電柱・街路樹は 52%の正解率で除去できた。追加に比較して除去の精度が悪くなった理由は、クラスタの認識が完全でない場合、統合後の3次元点群地図に点群が残るからである。そのため、建物は完全に一つのクラスタとして認識することが難しく一部が残存したため、電柱・街路樹




図 15 静的物体追加後の
3次元点群地図図例

Fig. 15 After addition of
static object.




図 16 静的物体除去後の
3次元点群地図図例

Fig. 16 After removal of
static object.

の除去率よりも低くなったと考えられる。

3次元点群地図の一例を用いて、一つの建物が除去される様子を説明する。先程の追加の例とは時系列が逆であると考え、図14が基盤地図であり、図13が新たに取得した3次元点群地図次元点群地図である。この3次元点群地図同士を統合した結果が図16であり、3次元点群地図の建物が完全に除去できず一部が残存していることが分かる。これは、対象とした建物の高さが高いことで車両の上に搭載したLiDARから取得した点群が疎になっており、クラスタリングによってクラスタとして認識されなかった部分が除去されなかったためであり、より高精度なクラスタリング手法によってクラスタリングの精度を上げるか、除去の際には同一のグリッド範囲の点群を全て除去するなどの工夫を検討する必要がある。

4.4 提案手法の有用性に関する検証

本項では、4.3.2項で利用した3次元点群地図を対象に、路面判定・オクルージョン判定をしない場合、路面判定あり・オクルージョン判定なしの場合において3次元点群地図の更新を行った。この結果と4.3.2項の結果を比較することで、提案手法の有用性を示す。

3次元点群地図に対する静的物体の追加・除去の比較

3次元点群地図への建物の追加と除去の精度について述べる。表4は、50の建物のうち追加・除去に成功した割合を示している。なお、電柱・街路樹に関しては、路面判定やオクルージョン判定を行わない場合、近傍の路面や建物と一緒にクラスタを形成してしまい適切に評価を行うことができないため評価の対象から外した。表4の結果から提案手法が、最も精度よく建物の追加及び除去に成功していることが分かる。これは、時間差があるデータではオクルージョンの起き方が異なる場合でもより信頼できる部分でのみクラスタを形成して比較できたり、路面や近くの街路樹などとクラスタリングで一つのクラスタとしてまとめられにくくなったりすることに起因する。

更新後の3次元点群地図を用いた自己位置推定

提案手法によって差分抽出と更新を行った3次元点群地図を用いて、自動運転車両の自己位置推定を行う。比較対象は、更新前の3次元点群地図と、路面判定・オクルージョ

表 4 提案手法とオクルージョン判定・路面判定の有無における静的物体追加・除去の正解率

Table 4 Accuracy rate of update for point cloud map about approach and other.

	提案手法	オクルージョン判定なし	
		路面判定なし	路面判定あり
追加正解率 [%]	74	42	56
除去正解率 [%]	40	16	36




図 17 1 スキャンあたりの自己位置推定における NDT 誤差の総和
Fig. 17 Total NDT error of SLAM per scan.

ン判定を行わずに統合した3次元点群地図、路面判定のみを行いオクルージョン判定を行わずに更新を行った3次元点群地図の3つである。

図17は、LiDARから取得される点群(スキャンデータ)と、用意した各3次元点群地図の重ね合わせによる自己位置推定の際に算出可能なNDTの誤差総和を示している。図17の第二四分位数を確認すると、提案手法によって更新した3次元点群地図が最も精度良く自己位置推定できていることが確認できる。

3次元点群地図の統合にかかる処理時間の比較

3次元点群地図の更新は現状オフラインで行うため、リアルタイム性は求められない。しかし、3次元点群地図が普及した場合、更新の処理は頻繁に行われることとなり処理の効率化が求められる。

図18は提案手法と、路面判定・オクルージョン判定を行わなかった場合、路面判定のみを行った場合の統合処理における平均処理時間を示す。路面判定を行わなかった場合、全ての点群がクラスタリングの対象となるため、クラスタリングの処理時間が提案手法に対して約2.3倍かかる。加えて、オクルージョン判定を行わなかった場合も、街路樹や駐車車両といった点群と建物が隣接するためクラスタリングに約1.5倍の時間がかかる。このように、路面判定やオクルージョン判定は比較する対象となる点群を制限することによって、3次元点群地図の差分抽出・更新の精度を向上させつつ、処理の効率化を達成できた。

5. おわりに

5.1 まとめ

本論文では、2つの取得した時刻と場所が異なる3次元




図 18 地図統合に係る平均処理時間

Fig. 18 Average processing time of map integration.

点群地図に対して同一箇所判定をした後、2つの地図間の差分を抽出し新たな3次元点群地図として統合することで3次元点群地図を更新する手法を提案した。提案手法では、一定の高さ以上の点群に注目し動的な情報を排した上で、特徴量マッチングを行うことで3次元点群地図の同一箇所判定を行った。加えて、オクルージョンが発生している点群を視点情報がない状態から路面との関係を用いて推定することで判定し、静的な情報のみに限定した上でクラスタリングを適用し比較を行うことで差分を抽出した。評価では、動的な情報を排した特徴量マッチングを行うことで動的な情報を排除しなかった場合と比較して同一箇所判定の精度が約5.45倍向上したことを示した。差分抽出と地図更新においては74%の新規建物の追加、40%の消失建物の除去ができた。これは、提案した路面判定とオクルージョン判定を行わなかった場合と比較してそれぞれ、約1.76倍、2.5倍、検出率が向上しており提案手法の有用性を示した。加えて、更新した3次元点群地図において自動運転車両の自己位置推定を行った結果、自己位置推定の精度が向上し、3次元点群地図の更新が自動運転に有効であることを示した。

5.2 今後の課題

5.2.1 3次元点群地図環境に応じた特徴量マッチング

本研究では、特徴量抽出に対して動的なノイズを排除した上で特徴量抽出を行った。しかし、静的な情報においても建物が多い場所、少ない場所などの外的な要因や、新たな地図のセンサ種類による点群の密度の差などが存在する。これらの外的な要因や点群密度の差に応じて、より静的物体である信頼性が高いものの特徴量のみを抽出できると考えられる。

5.2.2 高精度な静的物体の認識

本論文の評価においては、点群のクラスタリング・セグメンテーション手法として最も一般的なユークリッド距離を用いた手法によって静的物体の抽出を行ったため、一部の物体検出結果が最適であるとは言いがたい。そこでディープラーニングやカメラ映像を併用したラスタリング・セグメンテーション手法を適用して静的物体を検出すること

で、より高精度に2つの3次元点群地図の差分を抽出し統合できると考えられる。

参考文献

- [1] A. Geiger, P. Lenz, and R. Urtasun, "Are We Ready for Autonomous Driving? The KITTI Vision Benchmark Suite," in *Proc. of IEEE Conference on Computer Vision and Pattern Recognition*, 2012, pp. 3354–3361.
- [2] W. LLC, "Waymo," <https://waymo.com/>, retrieved Jan. 10th, 2018.
- [3] S. Kato, S. Tokunaga, Y. Maruyama, S. Maeda, M. Hirabayashi, Y. Kitsukawa, A. Monroy, T. Ando, Y. Fujii, and T. Azumi, "Autoware on Board: Enabling Autonomous Vehicles with Embedded Systems," in *Proc. of the 9th ACM/IEEE International Conference on Cyber-Physical Systems*, 2018, pp. 287–296.
- [4] H. Alismail, L. D. Baker, and B. Browning, "Continuous trajectory estimation for 3D SLAM from actuated lidar," in *Proc. of IEEE International Conference on Robotics and Automation*, 2014, pp. 6096–6101.
- [5] J. Behley, V. Steinhage, and A. B. Cremers, "Efficient radius neighbor search in three-dimensional point clouds," in *Proc. of IEEE International Conference on Robotics and Automation*, 2015, pp. 3625–3630.
- [6] Z. C. Marton, R. B. Rusu, and M. Beetz, "On fast surface reconstruction methods for large and noisy point clouds," in *Proc. of IEEE International Conference on Robotics and Automation*, 2009, pp. 3218–3223.
- [7] R. B. Rusu, N. Blodow, Z. C. Marton, and M. Beetz, "Close-range scene segmentation and reconstruction of 3d point cloud maps for mobile manipulation in domestic environments," in *Proc. of IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2009, pp. 1–6.
- [8] R. Schnabel, R. Wahl, and R. Klein, "Efficient ransac for point-cloud shape detection," in *Computer graphics forum*, vol. 26, no. 2, 2007, pp. 214–226.
- [9] P. F. Felzenszwalb and D. P. Huttenlocher, "Efficient graph-based image segmentation," *International journal of computer vision*, vol. 59, no. 2, pp. 167–181, 2004.
- [10] R. Triebel, J. Shin, and R. Siegwart, "Segmentation and Unsupervised Part-based Discovery of Repetitive Objects," in *Proc. of Robotics: Science and Systems*, 2010.
- [11] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "Pointnet: Deep learning on point sets for 3d classification and segmentation," *Proc. Computer Vision and Pattern Recognition (CVPR), IEEE*, vol. 1, no. 2, p. 4, 2017.
- [12] Y. Zhou and O. Tuzel, "Voxelnet: End-to-end learning for point cloud based 3d object detection," in *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018, pp. 4490–4499.
- [13] A. Hornung, K. M. Wurm, M. Bennewitz, C. Stachniss, and W. Burgard, "OctoMap: An efficient probabilistic 3D mapping framework based on octrees," *Autonomous Robots*, vol. 34, no. 3, pp. 189–206, 2013.
- [14] 間野耕司, 石井一徳, 平尾公孝, 橘菊生, 吉村充則, A. Devrim, and G. Armin, "移動計測車両測量システム (MMS) により取得される点群の精度評価," *写真測量とリモートセンシング*, vol. 51, no. 4, pp. 186–200, sep 2012.
- [15] F. Tombari, S. Salti, and L. Di Stefano, "Unique Signatures of Histograms for Local Surface Description," in *European Conference on Computer Vision*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010, pp. 356–369.