

距離データに対する NDT を用いた高速な差分検出手法の提案

—屋内・屋外環境での差分検出精度の検証—

High-speed spatial change detection using point clouds and NDT

-Performance verification of spatial change detection in indoor and outdoor environments-

学 桂右京 (九大) ○学 松本耕平 (九大) 正 河村晃宏 (九大)
正 倉爪亮 (九大) 石上智英 (パナソニック (株)) 岡田典 (パナソニック (株))

Ukyou KATSURA, Kyushu University, katsura@irvs.ait.kyushu-u.ac.jp

Kohei MATSUMOTO, Kyushu University, matsumoto@irvs.ait.kyushu-u.ac.jp

Akihiro KAWAMURA, Kyushu University

Ryo KURAZUME, Kyushu University

Tomohide ISHIGAMI, Panasonic Corporation

Tsukasa OKADA, Panasonic Corporation

This research aims to develop a high-speed spatial change detection technique using point clouds and NDT (Normal Distributions Transform). Three techniques are introduced to make the proposed system robust for noise, that is, classification of point distribution, overlapping of voxels, and voting using consecutive sensing. This paper describes the results of performance verification of spatial change detection in indoor and outdoor environments.

Key Words: Spatial change detection, Point cloud, Anomaly detection, NDT, Range data

1 はじめに

近年, 日本では少子高齢化による労働力不足の解決のため, サービスロボットによる生活支援作業の実現が期待されている. サービスロボットの導入が望まれている分野は, 介護支援や清掃業務, 警備作業など多岐に渡るが, それらに共通して, 自己位置推定とロボット周囲の状況の理解は必要不可欠な機能である. 特に外部環境における異常や変化(差分)の検出は, 計画された動作の修正や警備作業では必須の機能である. そこで本研究では, 距離データを用いた高速な差分検出システムの開発を行う.

移動ロボットの位置推定手法として, これまで2次元の距離センサとあらかじめ取得した2次元地図データを比較し, 位置推定を行う手法が多く提案されている [1][2][3]. 一方, 近年, RGB-D カメラやレーザスキャナの低価格化により, ロボット周囲の様々な環境情報を含む3次元点群が手軽に取得可能になってきている.

そこで本研究では, 自律移動ロボットに搭載した距離センサで取得した3次元計測データと, レーザスキャナにより得られる3次元地図データを比較することで, 自己位置推定と差分検出を行う手法を開発する. しかし, 従来広く用いられている, 計測データと地図データに含まれる3次元点群を直接用いた Iterative Closest Point (ICP) 法 [4][5] では, 3次元点間の対応をすべて求める必要があり, 膨大な計算コストがかかってしまい, 実時間で自己位置推定や差分検出の処理を行うことはできない. 一方, 3次元距離データを用いた手法として, Normal Distributions Transform (NDT) [6] を使用した高速な自己位置推定手法が提案されている [7].

そこで我々はこれまでに, NDT により生成される ND ボクセルを使用することで, 高速かつノイズに頑健に差分検出を行う手法を開発した [8]. 本報告では, 移動ロボットに搭載したレーザ距離センサと RGB-D カメラを用いて, 移動ロボットで自動で移動しながら, 大規模空間で自己位置推定および差分検出を実時間で実行するシステムを構築し, 屋内・屋外環境での提案手法による差分検出精度の検証を行ったので報告する.

2 関連研究

本章では, 3次元距離データを用いた差分検出手法を紹介する. PCL の差分検出 [9] では, 位置合わせされた地図データと計測データの空間を格子状に分割し, 地図データの格子内には点が入っていないが, 計測データの格子内に点が存在する箇所を差

分とする, 最も単純な手法を紹介している. Andreasson ら [10] は, 地図データのみを ND ボクセル化 [6] し, 計測データの測定点と, 地図データの正規分布に含まれる確率を計算し, 差分検出を行う手法を提案した. Saarinen ら [11] は, 地図データと計測データを ND ボクセル化 [6] し, ボクセル内の分布の L_2 距離を計算し, 差分を検出する手法を提案した.

3 ND ボクセルを用いた高速な差分検出手法

本章では, NDT の際に生成された ND ボクセルを使用し, 高速に差分検出を行う方法 [8] の概略について説明する. 3次元距離データを用いた差分検出の従来手法 [10] では, 点ごとに比較するため時間がかかることや, 計測ノイズや位置推定誤差に脆弱といった課題が挙げられる. そこで, 開発した手法では, 頑健な差分検出を実現するために, 以下の3つの手法を用いている.

1. ボクセル内の点群の分布の分類
 - 点群の分布によって, 球, シート, 線の3つに分類する.
2. 地図データのオーバーラップ ND ボクセル化
 - 地図データの各格子を半分ずつ重複するように配置し, ND ボクセル化する.
3. 連続した計測データによる差分の正規分布に従った投票
 - 各フレームで差分として検出されたボクセルの27近傍に対し, 3次元正規分布に従った重みで投票を行う.

4 屋内での差分検出実験

自己位置推定には全周レーザ距離センサである Velodyne HDL-32e を, 差分検出には密な3次元点群が必要であるため, RGB-D カメラである Kinect V2 を採用した. 屋内実験におけるデバイス構成を図1に示す.

4.1 差分検出

屋内実験における大まかな流れを図2に示す. 屋内実験では, まず高精度レーザスキャナ (FARO Focus 3D) で8箇所撮影を行い, 地図データを作成した. 次に, 差分として図3の箇所に ①: $100 \times 100 \times 100 [mm]$ (①と⑤), ②: $200 \times 200 \times 200 [mm]$ (②と⑥), ③: $300 \times 300 \times 300 [mm]$ (③と⑦), ④: $400 \times 400 \times 400 [mm]$ (④

と⑧)の段ボールを設置し、移動ロボットで図3の矢印の経路を移動した。

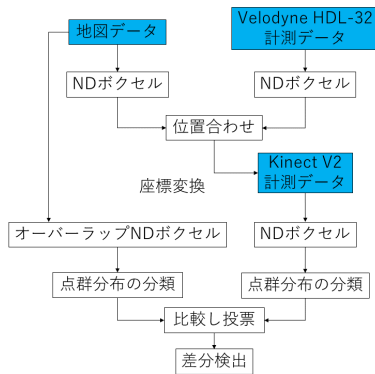



Fig.1 Velodyne HDL-32eとKinect V2

を搭載した移動ロボットを Fig.2 屋内実験における差分検出の流れ




Fig.3 差分設置箇所と移動経路

初期位置の決定は、まず適当な位置を手動で与えて、[7]の手法により Velodyne HDL-32e から得られた 3次元点群と地図データを ND ボクセルを用いて比較し、パーティクルフィルタで決定した。また、目標位置は手動で与えた。その後、ROSの Navigation パッケージを使用し、ダイクストラ法で経路を探索した。その後、移動ロボットを計画された経路に沿って自動で移動させ、Velodyne HDL-32e による位置情報 [7] とオドメトリ情報を 1Hz で融合した。その際、1Hz で出力される座標変換行列を用い、Kinect V2 の 3次元点群を地図データに位置合わせ、ND ボクセル化し、第 3 章の手法を用いて差分検出を行った。




Fig.4 差分検出結果

なお、ボクセルの大きさは自己位置推定、差分検出ともに 400[mm] とした。1Hz で投票を行いながら、図 3 の開始位置から終了位置までの約 20[m] の自律移動を行い、投票値が閾値を超えた箇所を差分として検出した結果を図 4 に示す。赤いボクセルが差分として検出された箇所である。

①の差分以外の検出に成功したが、誤検出が 1 箇所存在する。これは、地図データを取得する際にオクルージョンとなっている箇所、3次元点群が取得できていない。一方、計測データにおいてはその箇所の 3次元点群が取得できているので、誤検出が発生したと考えられる。

4.2 性能評価

表 1 に、10 回実験を行い、提案手法、3D-NDT の手法 [10]、L2 距離の手法 [11] の検出率の平均を算出したものを示す。

Table 1 4 種類の差分物体の検出率

差分物体 (サイズ)	検出率 [%]		
	提案手法	3D-NDT[10]	L ₂ [11]
A (400 × 400 mm)	100	100	95
B (300 × 300 mm)	100	100	95
C (200 × 200 mm)	85	75	50
D (100 × 100 mm)	50	15	0

また、表 2 に適合率と再現率、図 5 に PR 曲線と ROC 曲線を示す。表 2 中の、XOR(overlapped) は、[9] の地図データをオーバーラップする手法に拡張したものである。また、Classification は、ボクセル内の点群の分布の分類のみを用いて差分検出したものであり、Classification and overlapping は、ボクセル内の点群の分布の分類と地図データのオーバーラップ ND ボクセル化を用いて差分検出したものである。PR 曲線は縦に適合率 (Precision)、横に再現率 (Recall) をプロットしたグラフである。PR 曲線では、右に行くほど、精度が下がるが見落としが少ないという特徴を持っている。また、PR 曲線では、右上に分布があるほど、パフォーマンスがよいとされる。ROC 曲線は縦に再現率 (Recall)、横に FPR をプロットしたグラフである。ROC 曲線では、上に行くほど、真の差分物体の見落としは減るが、誤検出しやすいという特徴を持っている。また、ROC 曲線では、左上に分布があるほど、パフォーマンスがよいとされる。提案手法、3D-NDT の手法 [10]、L2 距離の手法 [11] のそれぞれに対して、投票の閾値を変化させていき、10 回の平均を算出し、グラフを作成した。

Table 2 適合率と再現率 [%]

	適合率	再現率
3D-NDT [10]	61.90	4.79
L ₂ [11]	81.19	1.11
XOR [9]	17.55	3.95
XOR (overlapped)	69.99	1.71
Classification	22.74	2.47
Classification and overlapping	61.77	26.06
提案手法	98.50	7.58




Fig.5 PR 曲線と ROC 曲線

PR 曲線では、提案手法の値がより右上にあり、ROC 曲線でも、提案手法の値がより左上にあることから、提案手法の有効性を示せた。

4.3 自己位置推定の誤差

トータルステーション (TOPCON GTP-9005A) により移動ロボットの位置の真値を取得し、Velodyne HDL-32e を使用した際の自己位置推定の誤差を算出した。表 3 に、ボクセルサイズ 400mm と 1000mm の際の平均誤差を示す。

Table 3 自己位置推定の誤差

ボクセルサイズ	平均誤差
400 [mm]	46.1 [mm]
1000 [mm]	74.2 [mm]

これより、位置推定誤差はおおむね 0.1m 以下であることがわかる。地図データのオーバーラップ ND ボクセル化により、0.2m 以下のずれであれば、点群の形状を捉えることができる。したがって、現在の自己位置推定の精度で、正しく差分検出が可能である。

4.4 実行時間計測実験

本研究の目的は、実時間で差分検出を行うことであった。そこで、差分検出および自己位置推定の実行時間の計測を行った。結果は全て 1 フレームあたりの平均実行時間である。

Table 4 実行時間

自己位置推定		827.2 [msec]
差分検出	3D-NDT[10]	570.0 [msec]
	L_2 [11]	17.2 [msec]
	XOR[9]	17.9 [msec]
	XOR (overlapped)	19.4 [msec]
	提案手法	20.4 [msec]

提案手法における差分検出の実行時間は十分小さく、高速に処理可能であることが確認できた。

5 屋外での差分検出実験

屋外環境では、太陽光により Kinect V2 で認識できる特徴量が減ってしまうため、屋外実験では、太陽光下でも特徴を頑健に認識することができる Velodyne HDL-32e を差分検出にも使用する。しかし、Velodyne HDL-32e の 3 次元点群は疎であるため、ロボットの移動方向に沿って 3 次元点群を重ね合わせ、密な 3 次元点群の生成を行う。その際、移動方向に平行な面の 3 次元点群は重ね合わせても、疎なままである。そこで、図 6 のように Velodyne HDL-32e を 15 度傾けて装着する。これにより、重ね合わせて際に移動ロボットの前方で密な 3 次元点群を取得できるようになる。

5.1 差分検出

屋外実験における大まかな流れを図 7 に示す。屋外実験では、まず高精度レーザスキャナ (FARO Focus 3D) で 3 箇所撮影を行い、地図データを作成した。次に、差分として図 8 の箇所に ①: $100 \times 100 \times 100$ [mm] (①と⑤), ②: $200 \times 200 \times 200$ [mm] (②と⑥), ③: $300 \times 300 \times 300$ [mm] (③と⑦), ④: $400 \times 400 \times 400$ [mm] (④と⑧) の段ボールを設置し、移動ロボットで図 8 の矢印の経路を移動した。



Fig.6 Velodyne HDL-32e を 15 度傾けて搭載した移動ロボット

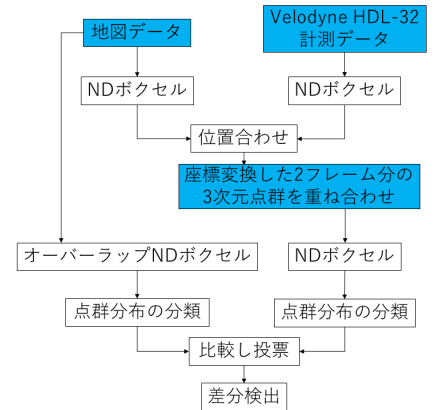


Fig.7 屋外実験における差分検出の流れ




Fig.8 差分設置箇所と移動経路

自律移動は屋内実験と同様に行った。屋外実験では、1Hz で出力される座標変換行列を用い、2 フレーム分の Velodyne HDL-32e の 3 次元点群を位置合わせ、重ね合わせを行い、ND ボクセル化し、ボクセル内の点群の分布の分類、オーバーラップ ND ボクセル化された地図データとの比較、差分箇所の正規分布に従った投票を行った。つまり、1Hz で自己位置推定を行い、2 フレーム分を重ね合わせるため、投票は 0.5Hz となる。0.5Hz で投票を行いながら、図 8 の開始位置から終了位置までの約 15[m] の自律移動を行い、投票値が閾値を超えた箇所を差分として検出した結果を図 9 に示す。赤いボクセルが差分として検出された箇所である。




Fig.9 差分検出結果

実験の結果, ①, ②, ⑤ は検出漏れした. これは, Kinect V2 と比べ, 3次元点群が疎であったため, 分類がうまくいかなかったことが原因と考えられる. また, 2箇所の誤検出に関しては, 窓ガラスの部分と, ブルーシートでオクルージョンとなってしまった部分である.

5.2 性能評価

表5に, 10回実験を行い, 提案手法, 3D-NDTの手法[10], L_2 距離の手法[11]の検出率の平均を算出したものを示す.

Table 5 4種類の差分物体の検出率

差分物体 (サイズ)	検出率 [%]		
	提案手法	3D-NDT[10]	L_2 [11]
A (400 × 400 mm)	100	100	100
B (300 × 300 mm)	100	85	100
C (200 × 200 mm)	50	0	50
D (100 × 100 mm)	5	0	0

また, 表6に適合率と再現率, 図10にPR曲線とROC曲線を示す. 提案手法, 3D-NDTの手法[10], L_2 距離の手法[11]のそれぞれに対して, 投票の閾値を変化させていき, 10回の平均を算出し, グラフを作成する.

屋内実験と同様に, PR曲線では, 提案手法の値がより右上にあり, ROC曲線でも, 提案手法の値がより左上にあることから, 提案手法の有効性を示せた.

Table 6 適合率と再現率 [%]

	適合率	再現率
3D-NDT [10]	59.22	5.63
L_2 [11]	79.56	2.76
XOR [9]	9.96	0.91
XOR (overlapped)	42.71	0.34
Classification	13.13	2.54
Classification, overlapping	28.62	28.08
提案手法	91.55	9.95




Fig.10 PR曲線とROC曲線

6 まとめ

本研究では, 3次元距離センサを搭載した自律移動ロボットに対し, 以下の3つの手法を特徴とするNDTを用いた高速でノイズに頑健な差分検出手法を開発した.

1. ボクセル内の点群の分布の分類
2. 地図データのオーバーラップNDボクセル化
3. 連続した計測データによる差分の正規分布に従った投票

屋内実験では, 移動ロボットに搭載したレーザ距離センサとRGB-Dカメラを用いて, 移動ロボットが自動で移動しながら, 大規模空間で自己位置推定および差分検出を実時間で行うシステムを構築した. 屋外実験では, 移動ロボットに搭載するレーザ距離センサを15度傾け, 自己位置推定を行いながら点群を重ね合わせることで, 密な3次元点群を取得し, 差分検出を行うシステムを構築した. また, 屋内・屋外環境に8つの物体を置いた場合の, 性能検証実験を行い, 提案手法の有効性を確認した.

参考文献

- [1] J.-A. Meyer and D. Filliat: "Map-based navigation in mobile robots: A review of map-learning and path-planning strategies," *Cognitive Systems Research*, vol.4, no.4, pp.283-317, 2003.
- [2] F. Dellaert, D. Fox, W. Burgard and S. Thrun: "Monte carlo localization for mobile robots," *Proc. of the IEEE International Conference on Robotics and Automation*, vol.2, pp.1322-1328, 1999.
- [3] S. Thrun, W. Burgard and D. Fox: *Probabilistic Robotics*. MIT Press, 2005.
- [4] A. Nuechter, H. surmann, K. Lingemann, J. Hertzberg and S. Thrun: "6D slam with an application in autonomous mine mapping," *Proc. of the 2004 IEEE International Conference on Robotics and Automation*, pp.1998-2003, 2004.
- [5] A. Nuechter, K. Lingemann, J. Hertzberg and H. Surmann: "6D slam-3D mapping outdoor environments," *J. Field Robot*, vol.24, no.8-9, pp.699-722, 2007.
- [6] P. Biber and W. Straber: "The normal distributions transform: a new approach to laser scanmatching," *Proc. of the 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.2743-2748, 2003.
- [7] 鄭 龍振, 倉爪 亮, 岩下 友美, 長谷川 勉: "大規模な三次元環境地図とRGB-Dカメラを用いた移動ロボットの広域位置同定", *日本ロボット学会誌*, Vol.31 No.9, pp.896-906, 2013.
- [8] 桂 右京, 倉爪 亮, 石上 智英, 岡田 典, 距離データに対するNDTを用いた高速な差分検出手法の提案, *日本機械学会ロボティクスメカトロニクス講演会 2017*, pp.2A2-O08, 2017.5.10-13
- [9] "Spatial change detection on unorganized point cloud data.", http://pointclouds.org/documentation/tutorials/octree_change.php.
- [10] H. Andreasson, M. Magnusson, and A. Lilienthal: "Has something changed here? autonomous difference detection for security patrol robots," *2007 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp.3429-3435, 2007.
- [11] J. P. Saarinen, H. Andreasson, T. Stoyanov, and A. J. Lilienthal: "3d normal distributions transform occupancy maps: An efficient representation for mapping in dynamic environments," *The International Journal of Robotics Research*, Vol.32, no. 14, pp.1627-1644, 2013.