

## 小型イメージングLIDARとDCNNによる位置姿勢推定

伊藤誠悟 平塚誠良 太田充彦 松原弘幸 小川勝

株式会社豊田中央研究所

## 1 はじめに

近年、消費者とサプライチェーンをつなぐ Industry4.0 の提唱とともに、製造、物流でのデジタル改革に関連する研究開発が活発に進められている。Industry4.0 における構成技術要素の一つとして、AGV (Automatic Guided Vehicle) 技術がある。AGV では、集荷場および目的地までの自律移動技術の実現が特に重要である。本報告では、自律移動技術における位置姿勢推定に関して、我々が研究している高感度受光素子 SPAD を用いた小型イメージング LIDAR (SPAD LIDAR) [1] と DCNN (Deep Convolutional Neural Network) を用いた手法の検討および評価を行う。

## 2 SPAD LIDAR

SPAD LIDAR [1] とは、TOF (Time Of Flight) 方式に基づく測距センサである。市販車への搭載を狙い、高感度受光素子 SPAD (Single-Photon Avalanche Diode) の技術 [2] [3] をコアに小型・低コストのイメージング LIDAR 技術の研究を進め、 $202 \times 96$  画素の距離データを 10fps で出力する手のひらサイズの試作機を完成させた (図 1(a))。受光部として、受光画素と信号処理回路を同一 LSI に実装した CMOS センサチップを製作することにより、幅 67mm × 高さ 73mm × 奥行 177mm の小型化を実現している。出力データとしては対象までの距離データ、環境の背景光データ、反射強度データが取得できる (図 1 (b))。センサドライバは ROS (Robot Operating System) [4] に対応しており、出力データは ROS 標準のデータ形式で取得できる。その他の主要諸元としては、視野角  $55 \times 9^\circ$ 、距離解像度は短距離モード時で約 0.035m である。



(a) 試作イメージング LIDAR



(b) 距離データ (左), 背景光データ (中), 反射強度データ (右)

図 1: LIDAR 外観 (a) と各種出力データ (b)

## 3 SPAD DCNN

SPAD DCNN は、SPAD LIDAR から得られる距離データ、背景光データ、反射強度データの 3 チャンネルデータを入力とし、ある環境における対象の存在有無および位置姿勢を出力する。出力は Deep Convolutional Neural Network [5] を用いて推定する。SPAD DCNN のアーキテクチャを図 2 に示す。SPAD LIDAR と DCNN を用いた位置姿勢推定の基本性能確認のため、本報告では畳み込み・プーリング層が 3 層 (conv1 ~ conv3 および pool1 ~ pool3)、全結合層が 2 層 (fc1, fc2) のプレーンネットワークとした。出力層は分類問題の解を出力するための層と回帰問題の解を出力するための層が並列に存在する。

分類問題と回帰問題を同時に解くマルチタスク問題の誤差関数として Ross らの方法 [6] [7] を用いた。式 (1) に誤差関数を示す。

$$Loss = L_{cls}(p, u) + \lambda[u \geq 1]L_{reg}(t^u, v), \quad (1)$$

$L_{cls}(p, u)$  は分類問題における真のクラス  $u$  に対する推定クラスの誤差、 $L_{reg}(t^u, v)$  は真の状態  $v = (x, y, z, qx, qy, qz, zw)$  に対する推定状態  $t_u$  の誤差である。真の状態  $v$  および推定状態  $t_u$  は位置 3 次元、姿

## Localization Method based on Small Imaging LIDAR and DCNN

Seigo Ito, Shigeyoshi Hiratsuka, Ohta Mitsuhiko, Matsubara Hiroyuki, and Ogawa Masaru  
TOYOTA CENTRAL R&D LABS., INC.  
480-1192, Aichi, Japan  
seigo@mosk.tytlabs.co.jp

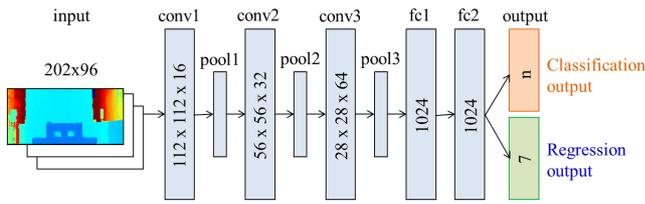


図 2: アーキテクチャ

勢 4 次元の 7 次元で構成する。  $L_{reg}$  は  $u \geq 1$ , すなわち対象が存在する場合のみ誤差を計算する。  $\lambda$  は分類誤差と回帰誤差との間のスケーリングファクターである。

## 4 評価

### 4.1 設定

SPAD DCNN を TensorFlow[8] を用いて実装し評価した。 TensorFlow とは Google が開発・公開している機械学習のためのライブラリである。 実験データ取得は SPAD LIDAR を小型移動体に搭載しデータを 10Hz で取得しながら、同時にモーションキャプチャによる 3 次元位置を 100Hz で取得する。 モーションキャプチャには VICON 社製のシステムを用いた。 SPAD DCNN モデル学習時は、モーションキャプチャから得られる 3 次元位置を教師データとして用い、評価時は SPAD LIDAR の出力データ (図 1 (b)) のみから 3 次元位置を推定する。 教師データは AGV の想定移動経路を走行し異なる日時に複数のデータセットを取得した。

### 4.2 結果

図 3 に実験環境における位置推定誤差を示す。 位置推定誤差はモーションキャプチャによる計測を真値とした場合の SPAD DCNN 推定値との Absolute Trajectory Error (ATE) [9] とする。 学習/評価には 3 種類のデータセット DS1, DS2, DS3 を用いた。 評価 A は DS1, DS2 を訓練データ, DS3 をテストデータとした。 同様に評価 B は訓練データ DS2, DS3 およびテストデータ DS1, 評価 C は訓練データ DS1, DS3 およびテストデータ DS2 とした。 結果, 評価 A では ATE 平均  $\mu_A = 0.046$ , 標準偏差  $\sigma_A = 0.031$ , 評価 B では  $\mu_B = 0.044$ ,  $\sigma_B = 0.022$ , 評価 C では  $\mu_C = 0.041$ ,  $\sigma_C = 0.025$  (単位: m) であった。 SPAD LIDAR の距離解像度は短距離モード時では約 0.035m であるため, 本結果は現状十分であると考えている。

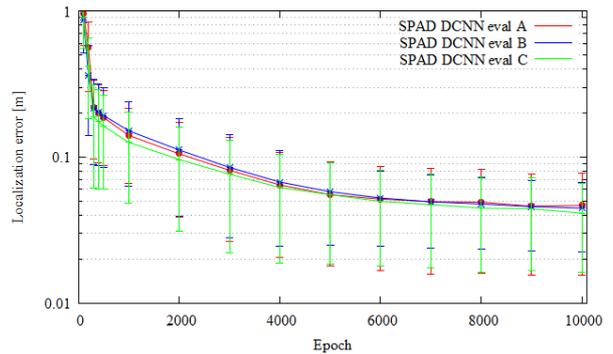


図 3: 位置推定誤差

## 5 まとめ

本稿では, SPAD LIDAR と DCNN を用いた位置姿勢推定に関して基本性能評価を実施し, 屋内実験環境で類似経路を走行した場合の DCNN による位置推定誤差 (ATE) は 0.044m であった。 SPAD LIDAR の距離解像度は短距離モード時では約 0.035m であるため, 位置推定誤差の改善が必要な場合はハード・ソフト両面からの改善を進める。 今後は, 多様な環境への対応のため SPAD DCNN に residual network [10] を適用した SPAD residual DCNN の評価を進める。

## 参考文献

- [1] 松原弘幸, "車載用小型イメージングレーザーレーダー", 第 41 回光学シンポジウム, 2016
- [2] C. Niclass, M. Soga, H. Matsubara, S. Kato, and M. Kagami, "A 100m-range 10-frame/s 340x96-pixel time-of-flight depth sensor in 0.18  $\mu$  m CMOS", IEEE Journal of Solid-State Circuits 48(2), p.559-572, 2013
- [3] C. Niclass, M. Soga, H. Matsubara, M. Ogawa, and M. Kagami: "A 0.18  $\mu$  m CMOS SoC for a 100m-range 10-frame/s 200x96-pixel time-of-flight depth sensor", ISSCC Dig. Tech. Papers, pp. 488-489, 2013
- [4] M. Quigley, et.al., "ROS: An Open-Source Robot Operating System", ICRA workshop, 2009.
- [5] 麻生英樹, 他, "深層学習", 近代科学社, 2015
- [6] R. Girshick, "Fast-R-CNN", arXiv:1504.08083v2, 2015.
- [7] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Toward Real-Time Object Detection with Region Proposal Networks", arXiv:1506.01497v3, 2015.
- [8] M. Abadi, et.al., "TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems", arXiv:1603.04457, 2016.
- [9] Sturm, J., Engelhard, N., Endres, F., Burgard, W. and Cremers, D., "A Benchmark for the Evaluation of RGB-D SLAM Systems", Proc. of the International Conference on Intelligent Robot Systems, 2012.
- [10] K. He, X. Zhang, S. Ren, J. Sun, "Deep Residual Learning for Image Recognition", arXiv:1512.03385, 2015.