深層学習と単体レーザーレンジファインダーを用いた 検知対象者の検出

小原 裕輝^{†1} 中沢 実^{†1}

概要:レーザーレンジファインダー (以下 LRF) は周囲の環境の形状で読み取ることができ,古くから SLAM や物体検知を行うために様々な研究で使われてきた.その中で,2次元方向の周囲の形状を読み取 れる LRF を用いて追跡対象者を検知し,その後を追うというタスクがある.この技術は人の代わりに荷 物を運ぶ貨物運搬ロボットに使われる.過去の研究では,人が設計した特徴を用いて追跡対象者を検知し, 追跡していた.近年,画像処理で革新を起こしている深層学習は人が設計した特徴を超える結果を出して いる.この論文ではその深層学習と単体 LRF を用いた追跡対象者の検知について検討,実験する.

キーワード:レーザーレンジファインダー,深層学習,点群,一クラス分類

tracking target detection using deep learning and single laser range finder

Yuki Kohara^{†1} Minoru Nakazawa^{†1}

Abstract: Laser Range Finder (LRF) can scan surrounding shape, so LRF has been used for various studies using Simultaneous Localization and Mapping (SLAM) and object detection for a long time. Among them, there is the task that LRF scan surrounding shape and then detect and track target person. The technology is utilized for robots which carry loads instead of human.Existing works have used hand-crafted features for target detection and tracking. Recently, deep learning cause innovation in computer vision, because it outweigh hand-crafted feature results. In this paper, we experiment on a method that use deep learning and single LRF for target detection.

Keywords: laser range finder, deep learning, point cloud, one-class classification

1. はじめに

レーザーレンジファインダー (LRF) は周囲の環境の形状 を読み取ることができ,自己位置推定と環境地図の作成を同 時に行う Simulateous Localization and Mapping(SLAM) や設置されているオブジェクトや障害物を認識する物体検 知 [22],歩行計測 [26] などが可能であり,研究の様々な場 面で利用されている.その LRF を使った研究の中で,周囲 の形状の中から追跡対象者を検知し,追跡する研究がある. この研究で養われた技術は人の代わりに荷物を運ぶ貨物

^{†1} 現在, Presently with Kanazawa Institute of Technology 運搬ロボットに使われ,実際に Doog 社の自動追従運搬ロ ボットのサウザー [1] は単体の LRF で人や同型のサウザー を検知,追跡することができる.過去の研究で LRF を用い た研究はいくつも行われており,単体の LRF を用いて人の 検知と追跡を行なっている研究も存在する [2],[3],[4],[5]. これらの論文が最新になるにつれて人が設計した特徴量 とークラス分類,点群による検知を採用していることがわ かる.

近年,コンピュータービジョンの分野で既存の手法を超 える結果を生み出している深層学習という機械学習の手法 がある.深層学習は既存の人が設計した特徴量を使わず, 深層学習モデル自身が自動的に特徴量を見つけそれを学習 することができる [23]. 深層学習モデルは人が設計した特 徴量では表現しきれない箇所も捉えることができるため, 人が設計した特徴量を使用した結果を超えることができ る [7]. 本研究では,深層学習と点群を利用した一クラス 分類モデルを用いて追跡対象者の検知手法で使われる特徴 量の比較実験を行う.本論文では,2章で本研究に関連す る研究の紹介,3章で深層学習を導入した点群の一クラス 分類モデル,4章で訓練またはテストデータの取得手法,5 章で実験,最後に6章でまとめについて説明していく.

2. 関連研究

最初に LRF で取得する検知部位に関する説明,次に人 が設計した特徴量について説明した後に点群と深層学習に 関して解説し,最後に深層学習と一クラス分類について説 明する.

2.1 既存研究で使われている検知部位

単体のLRFで追跡対象者を検知する手法において,LRF で検知する部位が足と胴体で分かれている.単体LRFを 用いて追跡対象者を検知,追跡するタスクを部位ごとに説 明する.

2.1.1 足の検知

奥迫らの手法 [2] は LRF を中心とした視点で, LRF から 見て影となる部分のパターンをあらかじめ取得しておく. 影の部分のパターンは LRF を中心とした区間ごとに種類 が分けられており、その区間に影がある場合はその影にあ うパターンがあるかどうかマッチングを行うことで検知 することができる. Chung らの手法 [4] は, LRF から得ら れるデータを点群として扱い、その点群内に人と認識可能 な点群があるかどうか調べている. 点群は 3D 情報を扱う のに特化したデータ形式であり、2Dの画像と比べてデー タ群は軸に規則的に並ばず,距離は3次元のユークリッ ド空間と同じように表現できる. Chung らは点群に対し て明らかにサイズが違うものに対してしきい値を設定し, その後残った点群に対して点群の特性を用いた3つの人 が設計した特徴量を計算し、それを Support Vector Data Description(SVDD)[24] に入力してそれが人の足であるか どうか検知している.図1の様に3つの特徴量は幅,胴回 り、奥行きであり、画像の形式では正確な値を出すことが できないものである.

2.1.2 胴体の検知

胴体検知ではどちらも点群と一クラス分類を使った手法 をとっている.Zainudinら [3] はカルマンフィルターを使 い,LRF で取得した点群の座標データに沿った点群の分 割を行っている.分割したデータが人であるかどうかを検 知するため,点群から人が設計した特徴量を作り出し,あ らかじめ学習させた RBF カーネルを用いたサポートベク ターマシン (以下 RBFSVM) の一クラス分類モデルに入力



図 1 Chung らの特徴量 ([4] を参考に作成) Fig. 1 Chung et al. features(created with reference to [4])

している. Jung ら [5] は胴体上部 (脇付近) を検知部位と しており, Chung ら [4] の特徴量に加えて角度と幅/胴回り を追加した後これらを標準化する. その後は Chung らと 同じように SVDD へ入力して人を検知している.

2.2 深層学習

深層学習と単体 LRF を使った人の検知を行うにあたり, 深層学習のデータの形式に点群を用いる.以下に人が設計 した特徴量から見た深層学習の優位性と,点群での深層学 習の活用について説明し,最後に一クラス分類と深層学習 について言及する.

2.2.1 人が設計した特徴量と深層学習

節2.1 で説明したように,既存研究では人が設計した特 徴量を機械学習モデルに入力し,RBFSVMやSVDDに入 力するという手法を取っている.人が設計した特徴量はそ の特徴量の設計者が自分の経験を元に設計したものであ り,またデータの細かな表現まで捉えることは難しい.深 層学習では訓練データから特徴量を自動的に抽出すること で様々なタスクをこなすことができる [8], [28].深層学習 の技術を用いて作られた AlexNet[7] は画像分類において 人が設計した特徴量を用いたモデルを超える結果を出して いる.

2.2.2 点群と深層学習

点群は2次元で軸に沿って規則的にデータ(ピクセル) が並んでいる画像と違って,不規則かつデータの順序を持 たない3次元の表現が可能な形式である.不規則であるた め,点群を画像と同じように深層学習を適応させることが できない.そのため点群が存在する空間に,軸に沿ったボ クセルを並べてその点群の情報をボクセルにまとめあげ, ボクセルに画像と同じような処理を施す手法を取った.こ の手法によって点群に深層学習を導入できた[27]が,こ の形式はボクセルに点群を合わせるという作業が必要な 上,ボクセル化による細かい情報の喪失,ボクセルの解 像度に依存する計算量によって手軽に扱えるものではな かった.この問題を解決したモデルが PointNet[6]である. PointNet はデータの順序の問題を解決したモデルであり,





図 2 AutoEncoder と PointNet を使った一クラス分類モデル ([6] を参考に作成) Fig. 2 One-class model using AutoEncoder and PointNet (created with reference to [6])

事前の準備なしにそのまま PointNet に点群を入力するこ とができる.また Spatial Transformer Networks(STN)[8] をモデルに組み込むことで剛体変換に対応できる様になっ ている.PointNet の汎用性の高さは PointNet の公開後に 作られた点群解析モデルに採用されていることからもわか る [10], [11].本研究でも点群の深層学習モデルに PointNet を採用する.

2.2.3 ークラス分類と深層学習

ークラス分類は入力されたものが正のデータであるか負 のデータであるかどうかを識別するだけの機械学習モデル である. 一クラス分類に似たものとして訓練またはテスト 時に二つの異なる種類のデータを入力しそれを分類する 2クラス分類があるが、一クラス分類で扱う訓練データは 正のデータだけである. そのため、本研究で扱うタスクの 様にあるものだけを学習してほしい場合はこの一クラス 分類モデルが使われる.深層学習モデル以外の一クラス分 類モデルとしてはサポートベクターマシンや SVDD があ る. 深層学習モデルでは AutoEncoder [9] が一クラス分類 に用いられることがある. AutoEncoder は入力データを低 次元表現である code に変換する Encoder と code から入 カデータと同じものを出力する Decoder に分かれている. 生成モデルとして扱われることが多いが, AutoEncoder で 入力データに似た出力データを生成できるのは訓練時に AutoEncoder に訓練させたデータに近い入力データのみで あるという条件があるため、この条件を生かし入力データ と似ていない出力データを偽のデータであるとみなす一ク ラス分類が可能となる [21]. またこの影響は Encoder にも 当てはまり, 訓練データに似た入力データが入力された時

に意味のある特徴量を生成できるという特徴がある [29]. 本研究では、この学習された AutoEncoder を介して生成 される特徴量を使い実験する.なお、近年でも GAN を用 いたークラス分類モデル [13] や深層学習と SVDD に着目 したモデル [14], AutoEncoder を発展させた Variational AutoEncoder[12] があるが、本研究では頻繁に扱われるこ とが多く尚且つシンプルな構造を持つ AutoEncoder を用 いる.

3. 深層学習を導入した点群の一クラス分類モ デル

本研究で使う深層学習を導入した点群の一クラス分類モ デルには節 2.2 で述べた PointNet[6] と AutoEncoder[9] を 使用する. そのモデルを図2の(a)に示し, このモデルを PointNet-AutoEncoder と呼ぶ. 図2の赤枠はn個の点か らなる入力点群から global feature と呼ばれる入力点群の 特徴量を抽出するための PointNet のアーキテクチャであ る. このアーキテクチャを AutoEncoder の Encoder とし て, global feature を Encoder から出力される code として 扱う. global feature を点群出力へ再構築する Decoder は 3つの全結合層であり、最後以外入力が1024次元で出力が 1024 次元となっている. 最後の全結合層のみ入力が 1024 次元で出力が n*3 次元となる. 訓練時は AutoEncoder が 出力点群を入力点群に近似するように学習させていく. ま た、2次元画像の AutoEncoder は損失関数としてピクセル ごとの差異を比べるが、点群はデータの並びに順番がない ため入力した点群と出力した点群を点単位で順に直接比べ ることはできない. そこで, Chamfer distance と呼ばれる



図 3 LRF から取得した点群データ Fig. 3 Point cloud data obtained from LRF

入力点群のある点とその点に最も近い出力点群の点の距離 を扱う手法を損失関数とする. S₁を入力点群, S₂を出力 点群, x を入力点群に含まれる点, y を出力点群に含まれ る点としたとき, Chamfer distance の定義式は

$$CD(S_1, S_2) = \sum_{x \in S_1} \min_{y \in S_2} \{ ||x - y||_2^2 \} + \sum_{x \in S_2} \min_{y \in S_1} \{ ||x - y||_2^2 \}$$

である.

4. LRF の点群データの取得手法

本研究では単体の LRF から取得した点群データを利用 して実験する.しかし,そのような点群データはオープン ソースで存在しないため自分で作成する必要があった.単 体の LRF には UTM-30LX[19] を採用することとし,以下 に点群データの取得環境の説明を示す.

4.1 使用するソフトウェアとライブラリ

LRF で取得した点群データを利用するため, Robot Operating System(ROS)[15] と Point Cloud Library(PCL)[16], Rviz を利用する. それぞれの説明を以下に示す.

4.1.1 ROS

ROS はロボット開発のためのソフトウェアであるが,環 境を簡単に導入でき,LRF を動かして取得値を参照でき尚 且つ点群データの処理専門のライブラリである Point Cloud Library(PCL)[16] を利用できるため,開発環境として採用 した.ROS は Node という形式で実行プログラムを扱い, Node を同時に複数管理することもできる.Node 同士で 通信を行うための通信形式も持ち合わせており,Publish と Subscribe という動作を行うことで簡単に通信できる. Publish とは Topic と呼ばれる場所に Node が送信したい 情報を公開することであり,逆に Topic に公開された情報 を読み取るのは Subscribe である.実装では LRF の取得 値を公開する Node(urg-node)[17] から取得値を処理する自 作の Node(observation-node) に取得値を送るためにこの 通信形式が使われる.



図 4 Rviz による LRF から取得した点群の可視化 Fig. 4 Visualization of point cloud obtained from LRF by Rviz

4.1.2 Point Cloud Library & Rviz

PCL[16] とは点群を扱うための C++ライブラリである. 点群は RGB-D カメラや LRF 等の現実空間にある物体を 3 次元情報としてコンピュータに取り込むことが可能なセ ンサーで使われる [25] ため,ロボットで使われることを想 定した ROS でも導入できる.しかし,urg-Node で公開す るデータの形式は LaserScan と呼ばれる形式であり,PCL で扱うための形式ではないため別途変換するためのクラス を用意した. Rviz は ROS の Topic で公開されているデー タを取得し,それを 3 次元空間上または 2 次元画像の映像 として表示することが可能な Node である.部位の点群を 保存する際に目的の点群が得られているかどうか確認する ために利用される.

4.2 LRF の取得値の処理と保存

urg-nodeから送られてきたLRFの取得値を observationnode が保存するまでのアルゴリズムを以下に示す。

(1)はじめにLRFを中心とした2次元空間があるとすると、前後の範囲は-1.0~4.0m、左右の範囲は-1.0~ 1.0mの範囲にある点群のみを残す.これはLRFで人を追跡するためのタスクであり、ロボットは基本的に追跡対象者のすぐ後ろを追跡すことを想定しており、遠方にあるオブジェクトを捉える必要性がないからで

Table 1 One-class classification result						
部位	足 (%)			胴体上部 (%)		
データ	正	偽	合計	正	偽	合計
Chung らの 3 つの特徴量 [4]	89.26	84.50	86.88	93.16	68.0	80.58
Jung らの 5 つの特徴量 [5]	86.36	96.23	91.30	85.39	84.10	84.75
PointNet-AutoEncoder	82.53	98.53	90.36	92.26	87.23	89.75

表 1 一クラス分類の結果 Table 1 One-class classification result



図 5 点群の分割 Fig. 5 Clustering point clouds



図6 足の点数と検知率の関係

Fig. 6 Relationship between the number of points of leg and detection rate

ある.また,LRF に映る点群は検知部位を得るための 人のみである必要があり,これは人以外のオブジェク トが映った場合,そのオブジェクトが訓練またはテス トデータに紛れ込むことを防ぐためである.

 (2)次に PCL のライブラリで使用できるクラスタリン グ[18]によって点群を分割する.クラスタリングされ た点群がどのように分割されるか可視化したものを図 5に示す.注意点として,図5はクラスタリングがど のような塊を作るかわかりやすいように示しているだ けであり,訓練もしくはテストデータを保存する際は 図5の様に様々なオブジェクトが並んでいるわけで はない.これらの点群にクラスタリングをかける理由 は、実際に追跡対象者を追いかける際に処理される点 群はクラスタリングを施した点群だからである.



図7 胴体上部と検知率の関係

Fig. 7 Relationship between the number of points of torso and detection rate

(3)分割された点群の中で最も点の数が多い塊を保存する.これは分割された点群をすべて保存してしまうと、LRFから見て足と足が被ってしまい陰に隠れてしまった足の一部のみが映った点群を保存してしまうことを防ぐためである.

このアルゴリズムを行っている間,LRFに映っている人 は歩行しながら検知部位まわりの形状をLRFに提供し点 群を保存させる.歩行中の足などよく動く部分を読み取る 時の検知部位の点群の形は変化しやすく,また,胴体上部 などの楕円形に近い形状は読み取る角度によってその点群 の形が変わりやすいため前述した方法で多様なデータを採 取する必要がある.LRFで読み取った点群を図3に示す. 図3のAが胴体上部,Bが足の点群である.注意点とし て,図3の点群は視認しやすいように点群から視点までの 距離と点のサイズを検知部位ごとに調節している.

5. 実験

5.1 準備

この実験では、4章で説明した方法で検知部位の点群を 取得したものを使ったークラス分類を行う.実験で扱う検 知部位は既存の研究で採用していた胴体上部と足である. 部位ごとに人の部位のみが映った 3000 個の訓練データを 用意し、これらを各手法で訓練に用いる.実験に用いる データは部位ごとに用意した正のテストデータ 3000 個と 偽のテストデータ 3000 個である.訓練データと正のテス トデータには様々な向きから見た部位のデータが入ってい

るが,データは全て一人の人間から収集したデータであり, 長ズボンを着用している.偽のデータには各部位の高さで 取れるデータを有しており,データ取得範囲には人が入っ ていないデータである. PointNet-AutoEncoder は図2の (a) で訓練させる. PointNet-AutoEncoder のみ, 3000 個 の訓練データのうち 600 個をバリデーションデータとして 扱い,残りの2400個を訓練データとして扱う.足と胴体 上部共に n=64 とし, 点の数が足りないもしくは多い場合 は、点群の点をnまで減らすもしくは点を複製するものと する. 点群の値は0から1で表せられる様に正規化する. 訓練のエポック数は 100, 最適化には Adam, 学習率はエ ポック数によって段々と変化するようになっている. 学 習率はエポック数が10になるまで0.001,20まで0.003, 100 まで 0.001 になるよう設定されている. 訓練された後, PointNet-AutoEncoder には訓練データを1エポック分入 力し, Encoderの出力に標準化を施したものを RBFSVM の一クラス分類モデルに入力し訓練させる. テストデータ で実験する際は、入力点群を Encoder に入力し Encoder の出力に標準化を施したものを、訓練させた RBFSVM の ークラス分類モデルに入力しテストデータが正か偽か判別 する.テスト時の流れを図2の(b)に示す.比較として, Chung らの 3 つの特徴量 [4] と Jung らの 5 つの特徴量 [5] を RBFSVM の一クラス分類モデルで判別させたものを示 す. また,検知部位ごとに n の数によって検知率がどう変 わるか示す.

5.2 結果

結果を表1に示す. Chung らの3つの特徴量 [4] の手法 は足を適切に検知できているものの,想定されていない胴 体上部の検知に関しては,偽のデータの誤検知が目立って いる. Jung らの5つの特徴量 [5] は標準化を行うことで Chung らの特徴量に比べて偽のデータをうまく見分けるこ とに成功しており,結果的に合計の検知率は上がっている. PointNet-AutoEncoder は足の正のデータを比較的正しく 検知できなかった. 胴体上部の検知率は正と偽のデータに 対して高い検知率を誇っており,合計値はどの手法よりも 優れていた.

5.3 検知部位の点の数と検知率

足の結果を図6に,胴体上部の結果を図7に示す.図7 と6の検知率は合計のものである.どちらの部位でも点の 数nが64である時、最も良い検知率を得ることができた. 今回はランダムに点を増減させたが,例えば全体の点の密 度が等しくなるような増減などの工夫した方法で点の数を 調節することで結果が変わる可能性も考えられる.

6. まとめ

深層学習モデルを利用した追跡対象者の検知を行った.

見る角度によって形が変化しやすい胴体上部の検知におい て, PointNet-AutoEncoder は的確に形状を捉えることが でき、人が設計した特徴量を超える検知率を出した.しか し、訓練データやテストデータを見る限り胴体よりも複雑 な形状を持たない足の検知において、人が設計した特徴量 の正のデータの検知率と比べて最大6%の差を出した.歩 行中の長ズボンの動きにより、ネットワークにとっては捉 えづらいランダムな形状になってしまったことなどが考 えられる.また、上記実験以外に人が設計した特徴量であ る Chung らの 3 つの特徴量 [4] と ROS, Raspberry pi 3 Model B+[20] と自作のロボットを利用して実際に追跡対 象者の検知と追跡を行なった.0.05 秒ごとに追跡対象者の 位置を更新する様に動作させ、問題なく人を追跡すること に成功している.この際に用いた訓練データの数は1000 個であり, 訓練データの中身も実験と比較して多種多様な 形状情報を持っていない上に限られた計算資源でも動作し ている. Raspberry pi 3 Model B+よりも圧倒的に性能が 上な Intel Core i5-2500k を搭載したパソコン上で LRF で 取得できる一回分のデータを学習モデルに入力し判定を出 すまでの時間を計測したところ、深層学習モデルが 0.0126 秒,人が設計した特徴量が0.0009秒であった.そのため, 上記の Raspberry pi 3 Model B+の様に計算資源が限られ る実環境では、深層学習モデルを使った追跡対象者の検知 と追跡は難しいと考えられる.以上より、人の部位を検知 して追跡する場合は人が設計した特徴量だけでも十分に追 跡対象者を捕捉できるため、このタスクで深層学習モデル を使う際は追跡対象の形状とそのタスクを行うための環境 を考慮することが必要となる.

参考文献

- 株式会社 Doog:株式会社 Doog サウザー,株式会社 Doog(オンライン),入手先 (http://jp.doog-inc.com/product-thouzer.html) (参照 2019-01-29).
- [2] 奥迫伸一,坂根茂幸.: レーザレンジファインダを用いた移動ロボットによる人の追跡,日本ロボット学会誌, Vol.24, No.5, pp.605 613(2006).
- [3] Zainudin, Z., Kodagoda, S. and Dissanayake, G.: Torso Detection and Tracking using a 2D Laser Range Finder, ResearchGate(オンライン), 入手先 (https://www.researchgate.net/publication/ 289888521_Torso_detection _and_tracking_using_a_2D_laser_range_finder) (参照 2019-01-29).
- [4] Chung, W., Kim, H., Yoo, Y., Moon, C. and Park, J.: The Detection and Following of Human Legs Through Inductive Approaches for a Mobile Robot With a Single Laser Range Finder, *IEEE Tran. on Industrial Electronics*, Vol.59, No.8, pp.3156-3166 (2012).
- [5] Jung, E., Lee, H.j., Yi, B., Park, J., Yuta, S. and Noh, S.: Development of a Laser-Range-Finder-Based Human Tracking and Control Algorithm for a Marathoner Service Robot, *IEEE/ASME TRANS. ON MECHATRONICS*, Vol.19, No.6, pp.1963-1976 (2014).
- [6] Qi, R,C., Su, H., Mo, K. and Guibas, J.L.: PointNet:

Deep Learning on Point Sets for 3D Classification and Segmentation, *Proc. CVPR 2017*, pp.652-660 (2017).

- [7] Krizhevsky, A., Sutskever, I. and Hinton, E.G.: ImageNet Classification with Deep Convolutional Neural Networks, NIPS 2012(オンライン), 入手先 (https://papers.nips.cc/paper/ 4824-imagenet-classification-with-deep-convolutionalneural-networks) (参照 2019-01-02).
- [8] Jaderberg, M., Simonyan, K., Zisserman, A. and Kavukcuoglu, K.: Spatial Transformer Networks, NIPS 2015(オンライン), 入手先 (https://papers.nips.cc/paper/5854-spatial-transformernetworks) (参照 2018-12-23).
- [9] Hinton, G. E. and Salakhutdinov, R. R.: Reducing the Dimensionality of Data with Neural Networks, *Science*, Vol.313, pp.504-507 (2006).
- [10] Deng, H., Birdal, T. and Ilic, S.: PPFNet: Global Context Aware Local Features for Robust 3D Point Matching, CVPR 2018(オンライン), 入手先 (http://openaccess.thecvf.com /content_cvpr_2018/CameraReady/1025.pdf) (参照 2019-01-12).
- [11] Qi, R.C., Yi, L., Su, H. and Guibas, J.L.: Spatial Transformer Networks, NIPS 2017(オンライン), 入 手先 (https://papers.nips.cc/paper/7095-pointnet-deephierarchical-feature-learning-on-point-sets-in-a-metric-space.pdf) (参)

照 2018-12-10).

- [12] Kingma, P.D. and Welling, M.: Auto-Encoding Variational Bayes, arXiv(オンライン), 入手先 (https://arxiv.org/abs/1312.6114) (参照 2019-01-31).
- [13] Schlegl, T., Seebck, P., Waldstein, M.S., Schmidt-Erfurth, U. and Langs, G.: Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery, arXiv(オンライン),入手先 (https://arxiv.org/abs/1703.05921) (参照 2018-12-22).
- [14] Ruff, L., Vandermeulen, R., Goernitz, N., Deecke, L., Siddiqui, A.S., Binder, A., Mller, E. and Kloft, M.: Deep One-Class Classification, *Proc. 35th ICML*, pp4393-4402 (2018).
- [15] ROS.org: ja ROS Wiki, 入手先 (http://wiki.ros.org/ja) (参照 2019-01-29).
- [16] pointclouds.org: PCL Point Cloud Library (PCL), 入
 手先 (pointclouds.org/) (参照 2019-01-29).
- [17] SOURCEFORCE: URG Network / Wiki / ROS_jp, 入 手先 (https://sourceforge.net/p/urgnetwork/wiki/ ROS_jp/) (参照 2019-01-30).
- [18] pointclouds.org : Euclidean Cluster Extraction, 入手先 (http://pointclouds.org/documentation/tutorials /cluster_extraction.php#cluster-extraction》(参照 2018-06-25).
- [19] 北陽株式会社:測域センサ データ出力タイプ /UTM-30LX 商品詳細 — 北陽電機株式会社,入手先 (https://www.hokuyo-aut.co.jp/search /single.php?serial=21) (参照 2019-01-20).
- [20] RASPBERRY PI FOUNDATION: Raspberry Pi 3 Model B+ - Raspberry Pi, 入手先 (https:// www.raspberrypi.org/products/raspberry-pi-3-model-bplus/) (参照 2019-02-01).
- [21] Chen, J., Sathe, S., Aggarwal, C. and Turaga, D.: Outlier Detection with Autoencoder Ensembles. *Proc. the* 2017 SIAM International Conference on Data Mining, pp.9098, (2017).
- [22] 兼時淳人,小林博明:レーザーレンジファインダを用 いた自律移動ロボットによる路面障害物検知に関する

研究, J-STAGE(オンライン), pp.605 613(2006). 入手先 (https://www.jstage.jst.go.jp/article/jacc/51/ 0/51_0_269/_article/char/ja/〉(参照 2019-02-02).

- [23] Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. and Batra, D.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization, *Proc. ICCV*, pp.618-626, (2017)
- [24] Chang, W., Lee, C., Lin, C.: A Revisit to Support Vector Data Description, 入手先 (https://www.csie.ntu.edu.tw/ cjlin/papers/svdd.pdf) (参照 2019-02-02).
- [25] IntelRealSence.: Projection in RealSense SDK 2.0 Intel-RealSense/librealsense Wiki, Github(オンライン) 入手先 (https://github.com/IntelRealSense/librealsense/wiki/ Projection-in-RealSense-SDK-2.0) (参照 2019-02-02).
- [26] 小澤真裕美,萬礼応,松村哲哉,高橋正樹:レーザレンジ ファインダを用いた歩行計測システムの提案,日本機械学 会論文集,Vol.79, No.801, pp.325-335 (2013).
- [27] Maturana, D. and Scherer, S.: VoxNet: A 3D Convolutional Neural Network for real-time object recognition, 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS),(オンライン), DOI: 10.1109/IROS.2015.7353481 (2015).
- [28] Badrinarayanan, V., Kendall, A. and Clipolla, R.: Seg-Net: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation, arXiv.org(オンライン) 入手 先 (https://arxiv.org/abs/1511.00561) (参照 2019-02-02).
- [29] Erfani, M.S., Rajasegarar, S., Karunasekera, S. and Leckie, C.:High-dimensional and large-scale anomaly detection using a linear one-class SVM with deep learning, *Pattern Recognition*, Vol.58, pp.121-134 (2016).