

1. はじめに

全方位 Light Detection And Ranging(LIDAR) を用いた従来の歩行者検出法 [1] では、点群データから垂直物をクラスタリングし、パーツごとに識別器を用いて重心位置を投票して歩行者を検出する。しかし、LIDAR を用いた歩行者検出法は、LIDAR が取得した距離値を 3 次元点群データに変換したデータを使用することで、歩行者を検出している。LIDAR で取得した全方位の距離データから 3 次元点群への変換は、計算コストが高い。そこで、本研究では全方位 LIDAR から取得した各レーザの距離値を、全方位レーザの距離値を取得する過程から歩行者検出する。これにより、識別時の計算コストを大幅に削減して歩行者検出を行う。

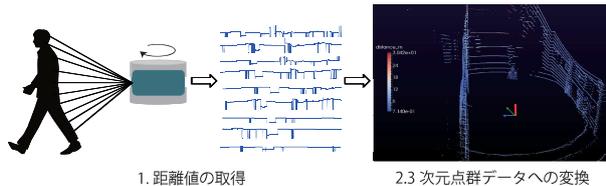


図 1：LIDAR の距離波形取得から 3 次元点群への変換

2. 提案手法

提案手法では、LIDAR で取得した距離値の波形データを用いることで歩行者を検出する。また、高精度な歩行者検出を行うために、Deep Convolutional Neural Network(CNN) を用いる。しかし、CNN は 2 次元の画像を入力し、2 次元の重みフィルタを入力画像に対して畳み込み処理をしている。そこで、提案手法では 1 次元の距離値の波形データを入力して、歩行者を検出する 1 次元畳み込みニューラルネットワーク (1D-CNN) を提案する。1D-CNN により、歩行者領域のを検出し、検出した領域から 3 次元点群データへ変換する。そして、変換した 3 次元点群データをクラスタリングすることで、歩行者の 3 次元形状を把握する。

2.1.1 次元畳み込みニューラルネットワークの構築

図 2 に、1D-CNN の構造を示す。1D-CNN に入力するサンプルは、LIDAR で取得できる 16 本の各レーザの距離値の波形データである。このとき、入力する範囲は 6° 分の距離値の波形データであり、入力層のサイズは 16×40 である。1D-CNN の 1 層目の畳み込み層では、入力層に対して 1×40 の重みフィルタを畳み込む。入力の距離値の波形データに対して、重みフィルタを畳み込むことで 16×1 の特徴マップを生成する。

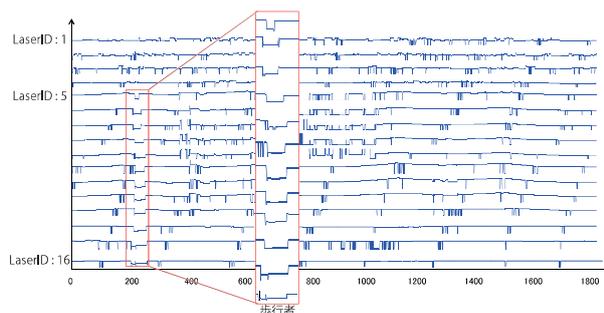


図 2：学習に使用する距離波形データ

2.2. 1D-CNN

図 3 に提案する CNN の構造を示す。各レーザに対して 1 次元の重みフィルタを畳み込む。このとき、1 層目で 1×16 の特徴マップを生成する。2 層目も同様に 1×16 の特徴マップに 1 次元の重みフィルタを生成する。これらの処理を繰り返すことで、最終的な特徴マップを全結合層へ入力することで歩行者の検出を行う。

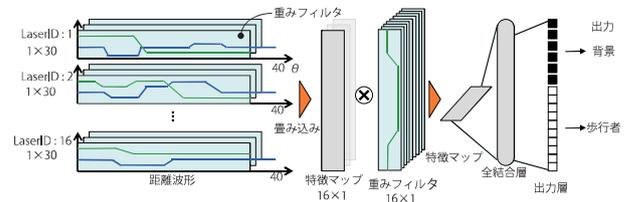


図 3：提案する CNN 構造

2.3. PCL による統合クラスタリング

1D-CNN の認識結果より歩行者の領域に対してクラスタリングを行う。クラスタリングには Euclidean Cluster Extraction 法を使用することで、点群間のユークリッド距離を用いてクラスタリングを行う。

3. 評価実験

提案手法の有効性を調査するために、実験を行う。

3.1. 実験概要

本実験で使用するデータは、縦に 16 本のレーザスキャナを内蔵した Velodyne VLP-16(以下、Velodyne) で撮影したデータを用いる。撮影したデータは室内の歩行者計 11 人分のシーンを使用する。このとき、Velodyne と歩行者との距離は約 2~9m である。学習サンプルには、約 2000 枚、評価サンプルには約 1169 枚使用する。

3.2. 実験結果

提案手法による歩行者の検出結果例を図 4 に示す。図 4 より画像中の歩行者に対してクラスタリングを行えていることから、歩行者が検出できていることが確認できる。また、入力するデータの特徴次元が少ないため、2msec という短い時間で歩行者の検出が可能である。



図 4：提案手法による歩行者の検出結果

4. おわりに

本研究では、LIDAR の距離データを用いた歩行者検出法を提案した。今後は、LIDAR と歩行者の距離によって CNN の重みフィルタが可変するアプローチを用いることで、歩行者検出をさらに高精度化する。

参考文献

- [1] L.Spinello, *et al*, "A Layered Approach to People Detection in 3D Range Data" AAAI, 2010.