

LIDARによる歩行者検出のための 複数フレーム特徴量に関する初期検討

建部 好輝[†] 出口 大輔^{††} 川西 康友[†] 井手 一郎[†] 村瀬 洋[†]
酒井 映^{†††}

[†] 名古屋大学 大学院情報科学研究科 〒464-8601 愛知県名古屋市千種区不老町

^{††} 名古屋大学 情報戦略室 〒464-8601 愛知県名古屋市千種区不老町

^{†††} 株式会社デンソー 〒448-8661 愛知県刈谷市昭和町 1-1

E-mail: [†]tatebey@murase.m.is.nagoya-u.ac.jp, ^{††}ddeguchi@nagoya-u.jp,

[†]{kawanishi,ide,murase}@is.nagoya-u.ac.jp, ^{††}†tutsushi_sakai@denso.co.jp

あらまし 本報告では、複数の時刻に亘って観測したLIDAR点群データから抽出する複数フレーム特徴量について検討する。特徴量の時間変化と点群の高密度化を利用する特徴量を検討し、実環境で収集したLIDARデータを用いて評価した。その結果、特徴量を複数組み合わせることで、従来の単一フレームから抽出する特徴量を利用した場合よりも高精度な歩行者検出が可能であることが示唆された。

キーワード LIDAR, 歩行者検出, 複数フレーム

A Preliminary Study on Multi-Frames Features for LIDAR-Based Pedestrian Detection

Yoshiki TATEBE[†], Daisuke DEGUCHI^{††}, Yasutomo KAWANISHI[†],

Ichiro IDE[†], Hiroshi MURASE[†], and Utsushi SAKAI^{†††}

[†] Graduate School of Information Science, Nagoya University

Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

^{††} Information Strategy Office, Nagoya University

Furo-cho, Chikusa-ku, Nagoya-shi, Aichi, 464-8601 Japan

^{†††} DENSO CORPORATION

1-1 Showa-cho, Kariya-shi, Aichi, 448-8661 Japan

E-mail: [†]tatebey@murase.m.is.nagoya-u.ac.jp, ^{††}ddeguchi@nagoya-u.jp,

[†]{kawanishi,ide,murase}@is.nagoya-u.ac.jp, ^{††}†tutsushi_sakai@denso.co.jp

Abstract In this report, we study multi-frames features extracted by integrating point-clouds of LIDAR over multiple frames. We studied on multi-frames features related to temporal changes and point-cloud density enhancement, and conducted experiments using LIDAR data obtained in an actual environment. Experimental results indicated that the combination of multiple features could detect pedestrians more accurately than using single-frame features.

Key words LIDAR, pedestrian detection, multi-frames

1. はじめに

近年、交通事故死者数の減少は鈍化傾向にあり[1]、さらなる対策が求められている。また、平成27年1月から11月末までの交通事故死者を分類すると、歩行者が36.5%と最も高い割合を示している[2]。このような背景から、自動車の周囲に存

在する歩行者を検出し、運転者に警告するシステムが強く求められている。

ここ数年では、上述のようなシステムの実現に向けた様々な研究が盛んに行われている。その中でも、車載センサとしてLIDAR (Light Detection And Ranging) を用いた研究が注目されている。これまでに、LIDARを用いた歩行者検出の研究

もいくつか提案されており、LIDAR の観測データに対する様々な特徴量が提案されている [3], [4]. Kidono らは、遠方の歩行者の検出を目的として、歩行者の大まかな形状をとらえるスライス特徴量と反射強度の分布に関する特徴量を提案した [3]. スライス特徴量の抽出手順を図 1 に示す. 図からわかるように、LIDAR によって観測された 3 次元点群を一定の高さで輪切り (スライス) にし、歩行者の大まかな形状としてスライスの幅と奥行を求める. また、物質毎に反射強度の分布が異なることから、反射強度の分布に関する特徴量は歩行者と非歩行者を識別する有効な特徴となる. これらの特徴量を組み合わせることで、遠方で比較的低解像度な点群として観測された歩行者の検出精度を向上させることに成功している. しかし、より遠方で非常に解像度が低くなる場合は検出精度が低い.

市川ら [4] は、このような低解像度で観測された歩行者の検出精度向上を目的とし、低解像度な点群からも計算可能な特徴量を提案している. 具体的には、スライス特徴量の相対位置を特徴量として提案している. スライス特徴量の相対位置の抽出手順を以下で述べる. まず Kidono らのスライス特徴量を求めた後、走査線毎に得られたスライスの端点間を直線で結ぶ. そして、その直線と鉛直方向がなす角度をスライス特徴量の相対位置として求める. つまり、スライス間の相対的な位置関係をとらえることで、歩行者の大まかな輪郭を表現する特徴量となる (以降、この特徴量をスライス間の相対位置と呼ぶ). しかし、電柱や木などの物体は円柱に近い形状を持つため、歩行者を観測した場合と類似した点群が得られる. そのため、それらの物体に対しての検出精度は依然として低い. また、市川らが提案する特徴量は、すべてある瞬間 (フレーム) の情報のみから抽出する特徴量であり、時系列情報を活用できていない. 点群の時間変化を用いることで、形状が変化する歩行者と形状が変化しない木や電柱のような物体は区別できる可能性がある. 更に、複数のフレームの点群を利用することで、より詳細な立体物の情報が把握できる. 本報告では、このような時系列情報を利用することで低解像度で観測された歩行者の検出率を改善する手法を検討した結果を報告する.

2. 低解像度 LIDAR を用いた歩行者検出

本手法では、LIDAR データの時系列情報を利用するために、2 つのアイデアを提案する. 1 つ目は、特徴量の時間変化をとらえるものである. 一般に、歩行者の移動速度より LIDAR を搭載した車両の移動速度の方が速いと考えられる. そのため、歩行者に向かって車両が走行するとき、車両は歩行者に徐々に近づいていく. また、LIDAR の 3 次元点群データは、より近い位置から取得したデータの方が高密度である. つまり、新しいフレームから得た特徴量ほど重要度が高まると考えられる. 2 つ目は、複数フレームの統合による点群の高密度化である. 一般に、LIDAR の LASER 光が当たる箇所は、同じ物体であっても各フレームで異なる. そのため、複数フレームの点群を位置合わせして重ね合わせることで、詳細な特徴が得られると考えられる. つまり、複数フレームの点群を重ねて特徴抽出に用いることで、安定して詳細な特徴量を得られると期待でき

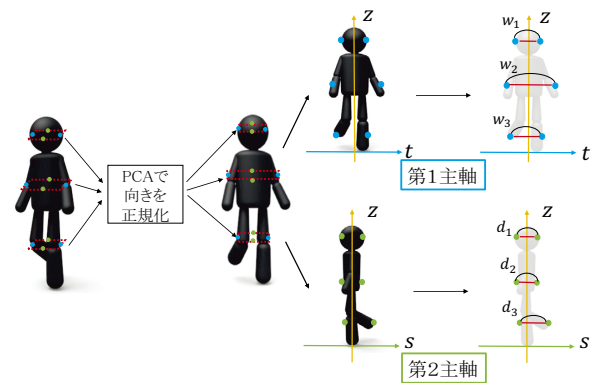


図 1 スライス特徴量の抽出手順

る. 上記の 2 つのアイデアに基づいて複数のフレームから特徴量を抽出することで、時系列情報を活かした低解像度 LIDAR からの歩行者検出を実現する. 複数のフレームから特徴量を抽出する具体的な方法については、2.3 節で述べる.

2.1 提案手法の概要

提案手法の処理手順を図 2 に示す. 提案手法は、事前に歩行者検出に使用する識別器を構築する学習段階と、観測した LIDAR データから歩行者を検出する検出段階の 2 段階に分かれる.

学習段階では、学習用の点群を用いて歩行者識別器を構築する. まず、学習用の点群として、歩行者点群 (Positive Sample) と非歩行者点群 (Negative Sample) を用意する. これらの学習用点群は、実環境で計測した LIDAR データに対して Ogawa らの [5] 立体物検出・追跡アルゴリズムを適用し、得られた各立体物に対して人手で歩行者か非歩行者かのラベル付けをすることで得られる. 次に、立体物を追跡して得られた一連の点群を 1 つの候補点群系列とし、候補点群系列内で連続する複数のフレームから 2.3 節で述べる形状や反射特性などの特徴量を抽出する. 最後に、これらの特徴量を用いて歩行者と非歩行者を識別する識別器を構築する. 識別器には、一般に高い認識性能を持つとされているカーネル SVM 識別器を用いる.

検出段階では、LIDAR から得られる 3 次元点群データに対して、学習段階と同様に立体物検出と追跡アルゴリズム [5] を適用し、立体物点群を抽出し候補点群系列とする. 次に、候補点群系列から学習段階と同様に特徴量を抽出する. 最後に、これらの特徴量を学習段階で構築した識別器に入力することで、歩行者候補点群が歩行者であるか否かを識別し、検出結果とする.

本報告では、学習段階では人手によるラベル付けまで、検出段階では立体物検出・追跡までは既存手法により既に処理されたデータを用い、特徴抽出の部分で新しい手法を提案する.

2.2 複数フレームを用いた特徴抽出

本手法では、複数のフレームに亘って観測した候補点群系列中の連続する M フレームから特徴量を抽出し、それを識別に用いることで歩行者検出精度を高める. 以降、複数フレームから抽出した特徴量を複数フレーム特徴量と呼ぶ.

複数フレームから特徴を抽出する利点としては、扱える点群の密度の増加に加え、フレーム間の変化を特徴として表現する

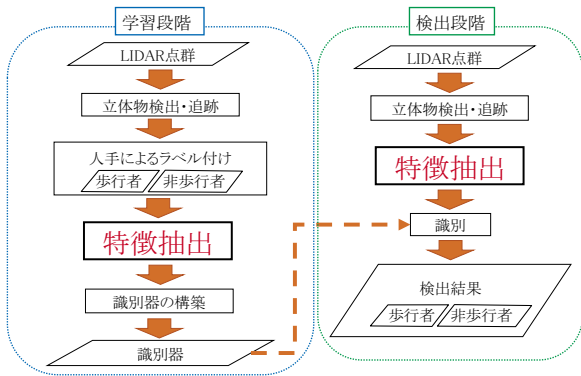


図2 提案手法の処理手順

表1 複数フレーム特徴量とその次元数

特徴量名		次元数
f_1	スライス特徴量の加重平均	$2L$
f_2	スライス間の相対位置の加重平均	$4(L-1)$
f_3	正規化反射強度の最大値の加重平均	1
f_4	正規化反射強度の分散の加重平均	1
f_5	点数相対比	L
f_6	局所正規化反射強度の最大値	$4L$
f_7	局所正規化反射強度の平均	$4L$
f_8	局所反射強度の最大値	$4L$

ことができる点が挙げられる。一方、欠点としては、 M フレーム以上観測されない歩行者候補点群からはその特徴を抽出できず、また初期検出が M フレーム遅れることが挙げられる。しかし、短期間しか観測されなかった歩行者候補点群は誤検出である可能性が高く、また、 M を小さくすることでこのような問題もある程度回避することが可能である。

2.3 複数フレーム特徴量の抽出手順

本節では、歩行者候補点群から複数フレーム特徴量を抽出する手法について述べる。

まず各特徴量の抽出を行う前に、事前処理として M フレーム分の歩行者候補点群の全ラインを道路面に射影し、フレーム毎に PCA を施す。次に、PCA によって得られたフレーム毎の主軸を座標軸とし、各点群の重心が原点となるように点群を平行移動する。この事前処理によって、各フレームの点群の向きと位置を正規化する。

次に、正規化済みの点群から抽出する各特徴量について述べる。提案手法で用いる特徴量の一覧と歩行者候補点群が L 本の走査線で観測された場合の各特徴量の次元数を表1に示す。本報告では、ある1つの走査線で観測された点群をラインと呼び、歩行者候補点群に含まれる走査線の本数 L を構成ライン数と呼ぶ。また表1中の反射強度は、LIDAR から得られた各点の反射光の強度を示す波形の最大値である。一方、反射光は距離の二乗に反比例して減衰するため、計測された各点までの距離の二乗を乗じることで正規化を行い、その値を正規化反射強度とする。本報告では大きく分けて、1つ目のアイデアである特徴量の時間変化から着想を得た $f_1 \sim f_4$ と、2つ目のアイデアである点群の高密度化から着想を得た $f_5 \sim f_8$ の2種類の特

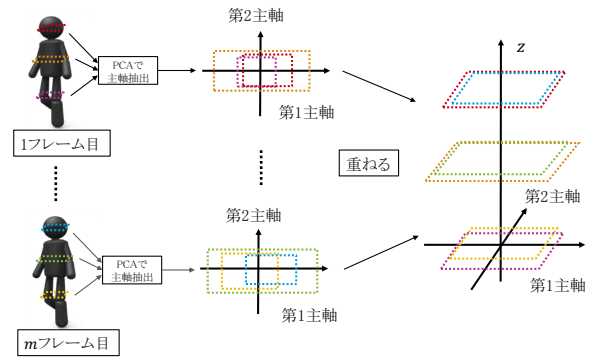


図3 点群統合手順 ($L=3$)

徴量を検討する。以下、各特徴量の具体的な計算手順を述べる。

2.3.1 特徴量の時間変化: $f_1 \sim f_4$

特徴量の時間変化のアイデアを実現するために、スライス特徴量とスライス間の相対位置、正規化反射強度の最大値、正規化反射強度の分散を連続する M フレームから抽出し、それらを新しいフレームほど重みが高くなるように加重平均して特徴量とする。

以下で、 M フレームの点群において加重平均を計算する際の手順を説明する。ここで、 f^k は k 番目のフレームから抽出した特徴量であり、 $\overline{f^k}$ は $k-1$ 番目と k 番目のフレームから抽出した特徴量の加重平均値とする。また、 w_1 は f^1 に対する重みであり、 $\overline{w_1}$ は $\overline{f^1}$ に対する重みである。まず、1番目のフレームから抽出した特徴ベクトル f^1 と2番目のフレームから抽出した特徴ベクトル f^2 で加重平均特徴量 $\overline{f^2}$ を計算する。このとき、重みは $(w_1 : w_2) = (0.4 : 0.6)$ とする。次に、先ほど求めた $\overline{f^2}$ と3番目のフレームから抽出した特徴ベクトル f^3 で加重平均特徴量 $\overline{f^3}$ を計算する。このとき、重みは先の処理と同様に $(\overline{w_2} : w_3) = (0.4 : 0.6)$ である。これを M 番目のフレームまで繰り返し、最終的に得られた加重平均値 $\overline{f^M}$ を特徴量とする。この計算は以下の漸化式 (1) で表現できる。

$$\overline{f^k} = 0.4\overline{f^{k-1}} + 0.6f^k \quad (1)$$

ただし、 $\overline{f^1} = f^1$ である。最終的に得られる特徴ベクトル $\overline{f^M}$ の次元数は、加重平均前の特徴ベクトルと等しく、表1の通りである。

2.3.2 点群の高密度化: $f_5 \sim f_8$

ここでは、複数フレームの点群を統合することで点群の高密度化を行い、特徴量を求める。以下では、特徴抽出に利用する M フレームの点群を統合する際の詳細な手順を説明する。構成ライン数が3本 ($L=3$) の場合の点群統合手順を図3に示す。このように、事前処理を施した M 個の座標空間を座標軸に沿って重ねることによって点群を統合する。

上記の手順で得た点群から抽出する2つの特徴量について説明する。ここで提案する各特徴量は複数フレームの統合による点群の高密度化を利用するため、単一フレームから求めるスライス特徴量などと比べてより多くの点を特徴抽出に利用することができるものである。

- 点数相対比: f_5

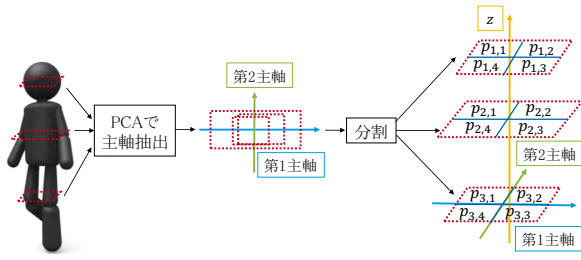


図4 局所特徴量を抽出する際の領域分割手順 ($L = 3$)

• 局所特徴量: $f_6 \sim f_8$

ただし、これらの特徴量は単一フレームからも求めることができる。以下では、1フレームから抽出する場合を例にとって説明する。

a) 点数相対比: f_5

点数相対比は、各ラインを構成する点数の相対比で形状を表現する特徴量である。以下で点数相対比の抽出手順を説明する。まず、入力点群の各ラインを構成する点数 c_l ($l = 1, 2, \dots, L$) を求める。次に、それらの点数を入力点群全体の点数で正規化し、 α_l ($l = 1, 2, \dots, L$) を得る。全体の処理を式で表現すると以下の式(2)のようになる。

$$\alpha_l = \frac{c_l}{\sum_{l=1}^L c_l} \quad (2)$$

このようにして得た α_l を連結することで1つの特徴ベクトルとする。この特徴ベクトルの次元数は構成ライン数によって変化する。構成ライン数が L 本の場合、ライン l ($l = 1, 2, \dots, L$) から1つの特徴量 α_l が得られ、全体として次のような L 次元の特徴ベクトル f_5 が得られる。

$$f_5 = \{\alpha_1, \dots, \alpha_l, \dots, \alpha_L\}$$

b) 局所特徴量: $f_6 \sim f_8$

局所特徴量は点群の局所領域に対し、正規化反射強度の最大値および平均と反射強度の最大値を抽出した特徴量である。以下で局所特徴量の抽出手順を説明する。まず、図4のように領域分割を行う。事前処理によって得た座標軸に従って、各ラインの点群をその重心を中心に4分割する。このようにして分割された領域毎に特徴量を求めて連結することで、1つの特徴ベクトルとする。この特徴ベクトルの次元数は構成ライン数によって変化する。構成ライン数が L 本の場合、ライン l ($l = 1, 2, \dots, L$) の4つの局所領域 $p_{l,1}, p_{l,2}, p_{l,3}, p_{l,4}$ から、それぞれ特徴量 $\beta_{l,1}, \beta_{l,2}, \beta_{l,3}, \beta_{l,4}$ が得られる。ここで $\beta_{l,1}, \beta_{l,2}, \beta_{l,3}, \beta_{l,4}$ は各特徴量をライン l の4つの局所領域から抽出したものである。よって、全体として $4L$ 次元の特徴ベクトル $f_6 \sim f_8$ が得られる。 $f_6 \sim f_8$ は以下のように表される。

$$f_i = \{\beta_{1,1}, \beta_{1,2}, \beta_{1,3}, \beta_{1,4}, \dots, \beta_{l,1}, \beta_{l,2}, \beta_{l,3}, \beta_{l,4}, \dots, \beta_{L,1}, \beta_{L,2}, \beta_{L,3}, \beta_{L,4}\} \quad (i = 6, 7, 8)$$

2.4 識別器の構築

前節で求めた特徴量を入力とし、SVMを用いて歩行者識別器を構築する。本報告では、RBF (Radial Basis Function) カー

表2 構成ライン数別の歩行者/非歩行者数

	構成ライン数 L			
	$L = 3$	$L = 4$	$L = 5$	$L = 6$
歩行者	1,002	5,269	6,934	8,189
非歩行者	5,726	5,904	7,236	13,535

表3 単一フレーム特徴量とその次元数

特徴量名	次元数
f_9 スライス特徴量	$2L$
f_{10} スライス間の相対位置	$4(L-1)$
f_{11} 正規化反射強度の最大値	1
f_{12} 正規化反射強度の平均	1
f_{13} 正規化反射強度の分散	1
f_{14} 反射強度の最大値	1

表4 評価に用いた各手法で使用した特徴量

	提案手法	比較手法1	比較手法2
$f_1 \sim f_4$	✓		
$f_5 \sim f_8$	✓		✓
$f_9 \sim f_{14}$		✓	✓

ネルを用いた。

3. 評価実験

本節では、提案手法の有効性を確認するために行った実験について述べる。

3.1 実験手順

本実験では走査線数が6本の低解像度 LIDAR を用い、実環境でデータ収集を行った。得られたデータに対して Ogawa ら [5] の立体物検出・追跡アルゴリズムを適用し、抽出された立体物の点群データを手法の入力として用いた。実験に用いたデータを構成ライン数別に集計した結果を表2に示す。歩行者候補点群を構成ライン数別に分割し、それぞれに対して5分割交差検定法により性能を評価した。また、データセットを分割する際に同一候補点群系列のデータを別の分割に振り分けないように、候補点群系列単位で振り分けた。これにより、学習データと評価データに同じ物体から得られた点群が含まれないようにした。評価指標としては、ROC (Receiver Operating Characteristic) 曲線と AUC (Area Under the Curve) を用いた。本実験では提案手法、比較手法1、比較手法2の3つの手法を評価した。提案手法は、3フレームから抽出した特徴量を使用し、3フレーム毎に1つの識別結果を算出する手法である。比較手法に関しては、上記の3フレーム中の各フレームごとに得た ROC 曲線と AUC の平均を最終的な評価に用いた。いずれの比較手法でも、従来の単一フレームから抽出する単一フレーム特徴量を使用した。単一フレーム特徴量の一覧を表3、各手法で使用した特徴量を表4に示す。

3.2 実験結果

実験により得られた各手法の構成ライン数別の ROC 曲線を図5~8に示す。誤検出率 (FPR: False Positive Rate) が5%の近傍に注目すると、提案手法は比較手法1及び比較手法2と比べて検出率 (TPR: True Positive Rate) が上回っており、




図5 各手法のROC曲線 ($L = 3$)

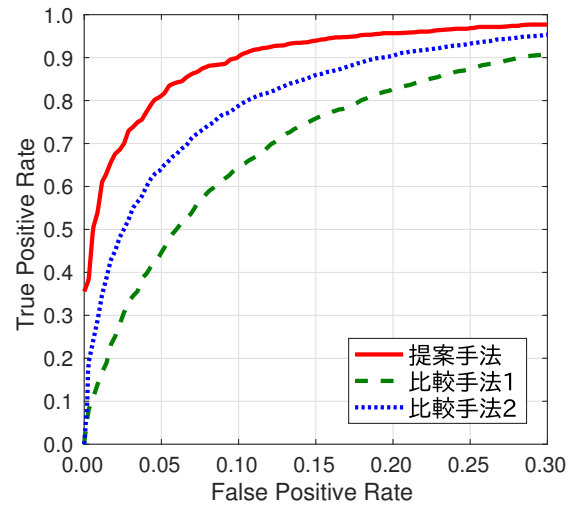


図6 各手法のROC曲線 ($L = 4$)




図7 各手法のROC曲線 ($L = 5$)




図8 各手法のROC曲線 ($L = 6$)

表5 各手法のAUC (各構成ライン数における最大値は太字で示した)

手法	構成ライン数 L			
	3本	4本	5本	6本
比較手法1	0.926	0.891	0.958	0.954
比較手法2	0.941	0.930	0.978	0.975
提案手法	0.952	0.963	0.986	0.983

歩行者検出において重要である低FPRでの識別精度が向上したことがわかる。また、実験によって得られた各手法のAUCを表5に示す。提案手法は比較手法1及び比較手法2よりも高いAUCが得られていることがわかる。

4. 考察

4.1 検出精度の比較

図5~8の結果より、本報告で検討した特徴量を複数組み合わせることで、従来の単一フレーム特徴量を使用する場合と比べて高い精度で識別が可能であることを確認した。また、比較手法2では今回新たに検討した特徴量の一部である点数相対比と局所特徴量を単一フレーム特徴量から抽出したも

のも使用しているが、提案手法ほどの性能向上は見られなかった。点数相対比では全ての点を特徴抽出に利用することに加え、局所特徴量では、点群の高密度化により局所領域においても十分な点数が確保できるようになる。このため、複数のフレームから特徴量を抽出することが有効であったと考えられる。

4.2 各特徴量の寄与度の分析

各特徴量の検出精度向上への寄与度を貪欲法を用いて分析した。具体的には、各特徴量単体で精度評価を行い、最も良い結果が得られた特徴量を1つ選択する。次に、選択された特徴量に別の特徴量を新たに1つ追加し、最も高い性能が得られる特徴量の組み合わせを求める。これをすべての特徴量が選択されるまで繰り返す。貪欲法による特徴量の選択順を表6に示す。

表6を形状特徴と反射特性毎にまとめたものを表7に示す。なお、平均は各特徴量の全構成ライン数における順位の平均であり、その順に従い表にまとめた。構成ライン数が3, 4本の場合においては、反射特性に関する特徴量が上位に多く現れている。しかし、構成ライン数が5, 6本の場合においては、形状特徴であるスライス特徴量の加重平均、スライス間の相対位置の加重平均、点数相対比が上位に現れている。この結果から、

表 6 構成ライン数毎で有効な特徴量とその順位

順位	構成ライン数 L			
	3 本	4 本	5 本	6 本
1	局所正規化反射強度の最大値	正規化反射強度の最大値の加重平均	局所反射強度の最大値	局所反射強度の最大値
2	点数対比	点数対比	スライス特徴量の加重平均	スライス間の相対位置の加重平均
3	局所反射強度の最大値	局所正規化反射強度の最大値	スライス間の相対位置の加重平均	スライス特徴量の加重平均
4	スライス間の相対位置の加重平均	局所反射強度の最大値	点数対比	点数対比
5	正規化反射強度の分散の加重平均	局所正規化反射強度の平均	正規化反射強度の最大値の加重平均	局所正規化反射強度の最大値
6	局所正規化反射強度の平均	スライス特徴量の加重平均	局所正規化反射強度の最大値	局所正規化反射強度の平均
7	スライス特徴量の加重平均	スライス間の相対位置の加重平均	局所正規化反射強度の平均	正規化反射強度の分散の加重平均
8	正規化反射強度の最大値の加重平均	正規化反射強度の分散の加重平均	正規化反射強度の分散の加重平均	正規化反射強度の最大値の加重平均

表 7 構成ライン数毎で有効な特徴量とその順位 (特徴の種類別)

種別	特徴量名	構成ライン数 L				平均
		3 本	4 本	5 本	6 本	
形状	点数対比	2	2	4	4	3.0
	スライス間の相対位置の加重平均	4	7	3	2	4.0
	スライス特徴量の加重平均	7	6	2	3	4.5
反射	局所反射強度の最大値	3	4	1	1	2.3
	局所正規化反射強度の最大値	1	3	6	5	3.8
	正規化反射強度の最大値の加重平均	8	1	5	8	5.5
	局所正規化反射強度の平均	6	5	7	6	6.0
	正規化反射強度の分散の加重平均	5	8	8	7	7.0

表 8 構成ライン数毎で有効な特徴量とその順位 (アイデア別)

種別	特徴量名	構成ライン数 L				平均
		3 本	4 本	5 本	6 本	
変化	スライス間の相対位置の加重平均	4	7	3	2	4.0
	スライス特徴量の加重平均	7	6	2	3	4.5
	正規化反射強度の最大値の加重平均	8	1	5	8	5.5
	正規化反射強度の分散の加重平均	5	8	8	7	7.0
密度	局所反射強度の最大値	3	4	1	1	2.3
	点数対比	2	2	4	4	3.0
	局所正規化反射強度の最大値	1	3	6	5	3.8
	局所正規化反射強度の平均	6	5	7	6	6.0

構成ライン数が多くなるにつれて詳細な形状が観測できるようになり、形状特徴の重要度が高くなったと考えられる。

また、形状特徴と反射特性がいずれの構成ライン数においても 2 位までに選択されたため、形状特徴と反射特性がいずれも歩行者の識別に重要であることを確認した。形状のみでは木や電柱といった歩行者と形状が似た非歩行者物体との識別が難しい。一方、反射特性のみでは歩行者の服装の変化の影響を強く受ける。これらのことを踏まえると、形状特徴と反射特性を共に使用することで、相互の弱点を埋め合わせることができ、結果として性能向上につながったと考えられる。

次に、先ほどと同様に表 6 をアイデア毎にまとめたものを表 8 に示す。反射特性の特徴だけに注目すると、局所特徴量の順位が加重平均特徴量の順位よりも相対的に高いことが分かる。この傾向は、特徴量の時間変化をとらえるアイデアよりも、点群の高密度化のアイデアの方が効果的であったことを示唆している。本報告で使用している低解像度 LIDAR は、10 fps という比較的高い頻度で観測が可能である。本報告で特徴抽出を行った 3 フレームという範囲では歩行者の動きが非常に小さいことが考えられるため、特徴量の時間変化をとらえるアイデアは相対的に見て効果が小さかったと考えられる。

5. むすび

本報告では、低解像度 LIDAR を用いた歩行者検出のための複数フレーム特徴量を検討し、結果の分析を行った。具体的には、低解像度な歩行者を精度良く検出するために、複数の時刻に亘って連続的に観測した点群の情報を組み合わせて点群の解像度を高めるとともに、点群の時間的な変化をとらえる複数フレーム特徴量を提案した。そして、LIDAR により計測されたデータを構成ライン数別に分割して識別器を学習し、歩行者検出を行った。実環境で収集したデータを用いた実験により、提案する特徴量を複数用いることで、従来の単一フレームから抽出する特徴量よりも高い精度で識別が可能であることを確認した。また、各特徴量の性能向上への寄与度の分析も行い、提案した 2 つのアイデアのうち、点群の高密度化が効果的であることも確認した。今後の課題としては、単一フレーム特徴量との併用を考慮した識別手法の改良や、Partial AUC を利用した識別器の構築、特徴学習の適用などが挙げられる。

謝辞 本研究の一部は、科学研究費補助金による。

文 献

- [1] 警視庁, “平成 27 年中の交通事故死者数について”. <http://www.e-stat.go.jp/SG1/estat/Pdfdl.do?sinfid=000031358275>, Jan. 2016. (2016/06/22 参照).
- [2] 警視庁, “交通事故統計 (平成 27 年 11 月末)”. <http://www.e-stat.go.jp/SG1/estat/Pdfdl.do?sinfid=000031353144>, Dec. 2015. (2016/06/22 参照).
- [3] K. Kidono, T. Miyasaka, A. Watanabe, T. Naito, and J. Miura, “Pedestrian recognition using high-definition LIDAR,” Proc. 2011 IEEE Intelligent Vehicles Symposium, pp.405–410, June 2011.
- [4] 市川善規, 出口大輔, 井手一郎, 村瀬 洋, 三澤秀明, 酒井 映, “低解像度 LIDAR を用いた歩行者検出のための特徴量に関する検討,” 信学技報, 2014-PRMU-55, Oct. 2014.
- [5] T. Ogawa, H. Sakai, Y. Suzuki, K. Takagi, and K. Morikawa, “Pedestrian detection and tracking using in-vehicle LIDAR for automotive application,” Proc. 2011 IEEE Intelligent Vehicles Symposium, pp.734–739, June 2011.