

LiDAR を用いた歩行者検出器の車両周辺環境に応じた信頼度推定

久徳 遙矢¹⁾ 川西 康友¹⁾ 出口 大輔¹⁾ 井手 一郎¹⁾ 加藤 一樹²⁾ 村瀬 洋¹⁾

Scene-wise Reliability Estimation of Pedestrian Detection using LiDAR

Haruya Kyutoku¹⁾ Yasutomo Kawanishi¹⁾ Daisuke Deguchi¹⁾ Ichiro Ide¹⁾ Kazuki Kato²⁾ Hiroshi Murase¹⁾

Pedestrian detection results from a LiDAR data cannot be fully trusted in real environments. Therefore, it is necessary to consider whether the detector can be trusted in the environment of the input data. So we have been proposing an estimation system of pedestrian detectors' reliability adaptive to vehicle surrounding environments. This paper presents the construction method of reliability estimators. The proposed method defines and uses two types of reliability for oversights and false detections. Moreover, the proposed method constructs estimators for each reliability with global features and pedestrian-like, artifacts-like features. The experimental results showed that the proposed method could estimate the reliabilities.

KEY WORDS: Electronics and control, Image recognition system, Vehicle sensor, Pedestrian detection, Reliability (E1)

1. はじめに

近年、自動車の運転者支援技術や自動運転技術の開発が盛んであり、大いに注目されている。このような情勢の中、車両走行時の周辺環境認識技術は、それらの技術に関する要素技術として非常に重要なものである。特に歩行者検出技術は、その誤りが人身事故の発生に直結するため、非常に高い精度が必要となる。歩行者検出技術は、古くから監視カメラや車載カメラを対象として非常に盛んに研究されてきており、高精度な手法が多く確立されている(1, 2)。また近年、3次元点群情報を取得するセンサであるLiDARを車両に搭載し、点群情報から歩行者を検出する技術の研究も盛んに行なわれている(3, 4, 5, 6, 7)。しかし実環境において、いずれのセンサを用いた歩行者検出技術も、依然として検出精度に改善の余地がある。そのため、運転者支援技術や自動運転技術において、検出結果を完全に信頼して走行した場合、事故に繋がる可能性がある。このことから、単に歩行者の有無に関する情報だけでなく、その情報がどの程度信頼できるのかを把握する必要がある。すなわち実利用時に、歩行者検出器にとってどの程度誤りなく判定可能な入力データから得られた情報であるのかを考慮して活用する必要がある。

歩行者検出器の誤りとしては、歩行者の見落とし(未検出)および非歩行者の検出(誤検出)が挙げられる。カメラを用いた歩行者検出器の信頼度が低下すると考えられるシーンの例を図1に示す。図1(a)は、レンズフレアによる白飛びが生じている例である。このシーンでは左前方に2人の歩行者が存在しているが、歩行者検出器による検出は困難であると考えられる。また図1(b)は、黒つぶれが生じている例である。この



(a) Blown out highlights. (b) Clipped shadows.

Fig.1 Difficult scenes for detection with a camera.


シーンでは右前方に2人の道路を横断しようとする歩行者が存在しているが、図1と同様に歩行者検出器による検出は困難であると考えられる。このように、歩行者検出器の性能が向上したとしても、誤りの回避が困難である状況が存在する。そのため、歩行者検出結果に加えて、入力データの取得環境における歩行者検出器の信頼度を併せて考慮する必要がある。

同様に、LiDARを用いた歩行者検出器を用いた際に誤りが生じやすいと考えられるシーンの例を図2に示す。図2(a)は全景であり、図2(b)はその右前方を、図2(c)は同左前方を拡大したものである。図2(b)では、歩行者が壁の前に存在している。そのため、点群上で壁と一体化しやすく、歩行者検出器はこの歩行者を見落としやすいと考えられる。一方、図2(c)の領域には棒状の構造物が多く存在している。これらの構造物は歩行者と形状が類似しているため、歩行者検出器はそれらを誤って検出する可能性が高いと考えられる。以上のように、カメラにおける例と同様、LiDARを用いた歩行者検出についても入力データの取得環境における歩行者検出器の信頼度を考慮する必要がある。

そこで我々はこれまでに、車両周辺環境の違いに応じた歩行者検出器の信頼度推定手法について検討してきた(8, 9)。その中で、LiDARを用いた歩行者検出器の車両周辺環境に対する信頼度を定義し、その妥当性を確認した(9)。本発表では、その推定手法について検討した結果を報告する。

1) 名古屋大学 (464-8603 名古屋市千種区不老町)

2) 株式会社デンソー (448-8661 刈谷市昭和町 1-1)



(a) Full view. (b) Low reliability for oversights. (c) Low reliability for misdetections.

Fig.2 Examples of difficult scenes for detection with a LiDAR.

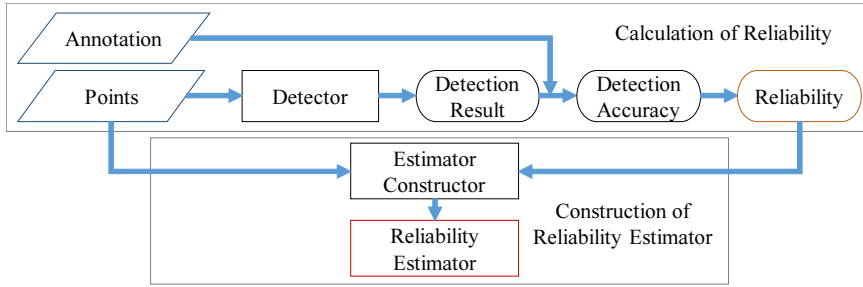


Fig.3 Training step.

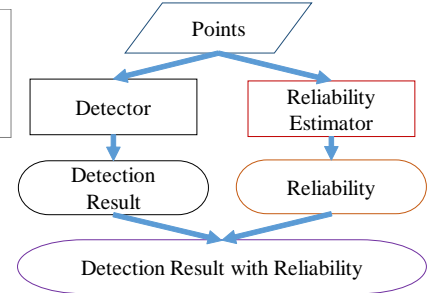


Fig.4 Estimation step.

2. 信頼度付き歩行者検出

本節では、我々の想定する信頼度付き歩行者検出の概要について述べる。信頼度付き歩行者検出は、学習段階と推定段階からなる。それぞれの処理の流れを図3、図4に示す。

学習段階は、学習に用いる信頼度の真値算出段階、および信頼度推定器構築段階からなる。まず信頼度算出段階では、入力点群から歩行者検出器を用いて検出結果を得る。この検出結果と、歩行者位置のアノテーション情報を用い、入力点群に対する検出器の信頼度を算出する。次に信頼度推定器構築段階では、入力点群と算出した信頼度を用い、入力点群から信頼度を出力する推定器を構築する。

続いて推定段階では、未知の入力点群から歩行者検出結果を得る。また、学習段階で構築した信頼度推定器を用い、入力点群の取得環境における検出器の信頼度を得る。これらを組み合わせ、信頼度付き歩行者検出結果として出力する。

3. 信頼度の定義

本節では、本稿で用いる車両周辺環境の違いに応じた歩行者検出器の信頼度の定義について述べる(9)。

歩行者検出器による検出結果における誤りとしては、歩行者の見落としと、非歩行者の検出の2種類がある。そのため、信頼度として未検出に関するもの、および誤検出に関するものの2つが考えられる。そこで我々は、それらを直接的に表す信頼度として、未検出に関する信頼度を検出率、誤検出に関する信頼度を適合率と定義した(8)。また、それらを間接的に表す信頼度として、未検出や誤検出が生じるしきい値から算出する指標を定義した(8,9)。本稿ではこれらのうち、しきい値を用いた信頼度を用いる。以降、しきい値を用いた信頼度の定義について詳細に述べる。

3.1 未検出に関する信頼度

未検出に関する信頼度として、次式で表される未検出数を最小とする最大の検出しきい値を用いる。

$$T_o = \max_t \{ \arg \min N_{FN}(t) \} \quad (1)$$

ここで、 t は $[0, 100]$ の値域をとる検出器の検出しきい値であり、 $N_{FN}(t)$ はそのしきい値における未検出数である。検出しきい値 t を変化させた際の正検出数 $N_{FN}(t)$ の例を図5(a)に示す。図のように、一般的に検出器は、しきい値が低い(緩い)ほど正検出が多くなり、高い(厳しい)ほど正検出が少なくなる。しきい値が低いほど誤検出も多くなるため、未検出が発生するしきい値は高いほど良いと言える。すなわち、未検出数を最小とする最大の検出しきい値 T_o は、高いほどその入力に対する検出器の信頼度が高いと言える。そのため、 T_o は次式のように未検出に関する信頼度 R_o として用いることが出来る。

$$R_o = T_o \quad (2)$$

3.2 誤検出に関する信頼度

誤検出に関する信頼度として、次式で表される誤検出数を最小とする最小のしきい値を利用する。

$$T_f = \min_t \{ \arg \min N_{FP}(t) \} \quad (3)$$

ここで、 t は $[0, 100]$ の値域をとる検出器の検出しきい値であり、 $N_{FP}(t)$ はそのしきい値における誤検出数である。検出しきい値 t を変化させた際の誤検出数 $N_{FP}(t)$ の例を図5(b)に示す。3.1節で述べたように、検出器はしきい値が高い(厳しい)ほど誤検出が少なくなり、低い(緩い)ほど誤検出が多くなる。しきい値が高いほど未検出も多くなるため、誤検出が発




Fig.5 Reliability indices.

生ずるしきい値は低いほど良いと言える。すなわち、誤検出数を最小とする最小の検出しきい値 T_f は低いほどその入力に対する検出器の信頼度が高いと言える。そのため、次式のように T_f の大小を反転させた値は誤検出に関する信頼度 R_f として用いることができる。

$$R_f = 100 - T_f \quad (4)$$

4. 信頼度推定器の構築

本節では、本稿で提案する信頼度推定器の構築手法について述べる。

提案手法では、まず LiDAR を用いて得られた入力点群から、その車両周辺環境を表現するための特徴を抽出する。そして、その特徴を入力とし、3. 節で述べた信頼度を出力とする信頼度推定器を構築する。この推定器には、RBF (Radial Basis Function) カーネルを用いた ϵ -SVR (Epsilon Support Vector Regression) を用いた。

ここで、多くの歩行者検出器は事前処理として点群のクラスタリングを行ない、得られた各クラスタが歩行者か否かを判定する。そのため提案手法においても、事前処理として点群のクラスタリングを行なう。そして、クラスタリングにより得られた各クラスタから、信頼度推定用の特徴を抽出する。入力点群から車両周辺環境を表現する特徴として、車両周辺環境を大まかに表現するための「全体特徴」と、誤りを引き起こしやすい物体の存在を表現するための「歩行者、人工物特徴」の2種類を抽出し、それらを結合した合計 291 次元のベクトルを用いた。以降、「全体特徴」と「歩行者、人工物特徴」について詳細に述べる。なお、 X, Y, Z 軸をそれぞれ自車を基準とした水平方向、奥行き方向、高さ方向として表現する。

4.1 全体特徴

車両周辺環境全体を表現するため、以下の特徴を結合した合計 118 次元ベクトルの特徴を抽出する。

- 3次元共分散行列

各クラスタの重心点群、すなわちクラスタ数個の点群から算出した3次元共分散行列を用いる。これは 3×3 の対称行列であるため、重複要素を除いた6つの要素を特徴とする。

- 3次元慣性モーメント

各クラスタの重心点群、すなわちクラスタ数個の点群か

ら算出した3次元慣性モーメントを用いる。これも 3×3 の対称行列であるため、重複要素を除いた6つの要素を特徴とする。

- クラスタまでの距離

各クラスタの重心までの距離群の統計量を用いる。統計量として、平均、中央値、標準偏差を算出する。さらに、 XY 平面上に投影した各重心点までの距離のヒストグラムを特徴として用いる。ヒストグラムは1 m 間隔、ビン数 100 個とした。

- 点数

各クラスタの点数の統計量を用いる。統計量として、平均、中央値、標準偏差を算出する。

4.2 歩行者、人工物特徴

車両周辺環境に存在する物体の歩行者らしさや人工物らしさを表現するため、以下の特徴を結合した合計 173 次元ベクトルの特徴を抽出する。

- 長身体物

一般的に、歩行者は Z 軸方向に細長い形状を持つ。そこで、 Z 軸方向に細長い形状を持つクラスタの割合を特徴として用いる。なお、各クラスタの幅および奥行きに比べて高さが大きいか否かを細長い形状を持つか否かの基準とする。加えて、 XY 平面上に投影した各クラスタの点群の面積の平均、中央値、標準偏差を特徴として用いる。

- 高さ

各クラスタ内の点群の Z 座標値の統計量を用いる。まず、各クラスタにおける Z 座標値の最大値、最小値、重心、高さを算出する。そして、それらの平均、中央値、標準偏差、ヒストグラムをそれぞれ算出し、特徴として用いる。最大値、最小値、重心のヒストグラムは0.5 m 間隔、ビン数 9 個とした。また、高さのヒストグラムは0.5 m 間隔、ビン数 10 個とした。

- 反射強度

各クラスタ内の点群の反射強度の統計量を用いる。まず、各クラスタにおける反射強度の最大値、最小値、重心、高さを算出する。そして、それらの平均、中央値、標準偏差、ヒストグラムをそれぞれ算出し、特徴として用いる。ヒストグラムはビン数 25 個として算出した。

- 平面度

一般的に、人工物は大きな平面形状を持つことが多い。そこで、各クラスタが持つ平面の点数の割合を特徴として用いる。平面を構成するとみなす点は、クラスタ内で大きい面積を持つ平面から最大で2つまでの平面を抽出し、それらに含まれる点とした。これを各クラスタから算出し、0%~100% までのビン数 10 個としてヒストグラムを算出した。



Fig.6 Experimental vehicle.

● 直線度

一般的に、人工物は長い直線形状を持つことが多い。そこで、各クラスタから抽出した直線の最大長を特徴として用いる。これを各クラスタから算出し、0 m～5 mまでのビン数 10 個としてヒストグラムを算出した。

5. 評価実験

本節では、提案した車両周辺環境に応じた信頼度推定器を実際の走行データを用いて構築し、評価した実験について述べる。

5.1 実験条件

評価用データセットとして、Velodyne LiDAR HDL-64eを図6の位置に設置した車両を用い、日中の市街道を走行し、歩行者を含む 26 本の点群系列データを取得した。各実験はある 1 系列を評価用とし、その他を学習用とする leave-one out 交差検証を用いて行なった。

なお、本実験では LiDAR から 40 m 以内に存在する遮蔽のない歩行者を検出対象とし、手動でアノテーションを与えた。

5.2 歩行者の検出

本節では、本実験で用いる歩行者検出器の構築手法について述べる。本稿で歩行者検出に用いる歩行者判別器では、歩行者らしさを表す特徴として、以下の特徴を用いた (9)。なお、座標軸は水平方向を X 軸、奥行き方向を Y 軸、高さ方向を Z 軸とする。

点群の座標から直接的に得られる特徴

判別対象点群の高さ、Z 座標の最大および最小、XY 平面における外接矩形の面積。また、それらの点数 (3) およびセンサからの最小距離 (3)。

点群の反射強度から得られる特徴

点群の持つ反射強度の中央値、平均 (3)、標準偏差 (3)、25 次元のヒストグラム (3)。

点群の座標を解析して得られる特徴

3 次元慣性モーメントの要素 (3)、3 次元共分散行列の要素 (3)、その固有値を元に算出する特徴 (10)。いずれも、対象のクラスタ重心を原点とした座標へ変換して算出する。3 次元慣性モーメントおよび 3 次元共分散行列は 3×3 の対称行列であるため、重複要素を除いた 6 つの要素を特徴とする。固有値を元に算出する特徴は、第 1 主成分から第 3 主成分に対応する固有値をそれぞれ $\lambda_1, \lambda_2, \lambda_3$ とし、表 1 で求める 7 種の

Table 1 固有値に基づく 3 次元点群特徴 (10)

Linearity	$(\lambda_1 - \lambda_2)/\lambda_1$
Planarity	$(\lambda_2 - \lambda_3)/\lambda_1$
Scattering	λ_3/λ_1
Omnivariance	$\sqrt[3]{\lambda_1\lambda_2\lambda_3}$
Anisotropy	$(\lambda_1 - \lambda_3)/\lambda_1$
Eigenentropy	$-\sum_{i=1}^3 \lambda_i \ln \lambda_i$
Change of curvature	$\lambda_3/(\lambda_1 + \lambda_2 + \lambda_3)$

値を特徴とする。

点群を基準とした座標系を元に得られる特徴

点群を主成分分析し、歩行者の鉛直方向を第 1 固有ベクトル \vec{e}_1 、同左右方向を第 2 固有ベクトル \vec{e}_2 、同前後方向を第 3 固有ベクトル \vec{e}_3 として以下のように算出する。

● 部分領域の 2 次元共分散行列 (3)

\vec{e}_1 を基準に上下に分け、さらに下半分を \vec{e}_2 を基準に左右に分け、3 つの部分領域とする。そして、それらの \vec{e}_1 - \vec{e}_2 平面における 2 次元共分散行列を算出する。これは 2×2 の対称行列であるため、それぞれの重複要素を除いた 3 要素を用い、合計 9 次元の特徴とする。

● 各平面における 2 次元点数ヒストグラム (3)

各点を \vec{e}_1 - \vec{e}_2 で構成されるグリッド平面に射影した際の 14×7 次元の点数ヒストグラム、および同様に \vec{e}_1 - \vec{e}_3 グリッド平面における 9×5 次元の点数ヒストグラム。

● スライス特徴 (3)

\vec{e}_1 方向に沿って等間隔に 10 個のブロックに分割し、それぞれ \vec{e}_2 - \vec{e}_3 平面に射影する。そして、各ブロックにおける各軸方向の分布幅を特徴とする。各ブロックで 2 次元の特徴となるため、合計 20 次元である。

以上の合計 225 次元の特徴を入力とし、Real AdaBoost(11)を用いて判別器を構築した。

5.3 信頼度推定器の評価

本節では、4. 節で述べた信頼度推定器を構築し、評価した結果について述べる。信頼度推定器は、5.2 節で構築した歩行者検出器を用い、3. 節で定義した信頼度を算出し、これを真値として構築した。なお、各系列で用いる信頼度推定器は、それ以外の学習用系列群を用いて構築した歩行者検出器およびその信頼度を用いて構築した。

5.3.1 信頼度推定結果

実験の結果、未検出に関する信頼度を平均絶対誤差 5.1 で、誤検出に関する信頼度を平均絶対誤差 3.3 で推定できた。例として、ある系列における推定結果を図 7 に示す。図 7(a) は未検出に関する信頼度の推定結果であり、図 7(b) は誤検出に関する信頼度の推定結果である。

誤検出に関する信頼度について、図 7(b) から、概ね良好に

推定できたことがわかる。一方、未検出に関する信頼度について、図 7(a) から、フレーム間の大小関係は概ね推定できたものの、大きく信頼度が低下した際に絶対値を良好に推定できなかったことがわかる。これは、見落としやすさを表現可能な特徴が不足していたためであると考えられる。また、未検出に関する信頼度の真値は、図 7(a) に値の無いフレームがあるように、検出対象となる歩行者が 1 人以上存在するフレームからのみ算出可能である。そのため、誤検出に関する信頼度と比べて学習用データが不足したことも一因として考えられる。

5.3.2 各信頼度が特徴的であったシーンの例

誤検出に関する信頼度 R_o の真値および推定値がともに低かった例として図 7(a) 中の青円で示すフレームを図 8(a) に、同様に高かった例として赤円で示すフレームを図 8(b) に示す。同様に、誤検出に関する信頼度 R_f の真値および推定値がともに低かった例として図 7(b) 中の青円で示すフレームを図 8(c) に、同様に高かった例として赤円で示すフレームを図 8(d) に示す。なお、図中の 3 次元枠は検出対象である遮蔽のない歩行者であり、青枠は点群と同時に取得された前方カメラ画像である。

図 8(a) では、ある歩行者が大きな車両の横を歩いており、 R_o が低下したと考えられる。一方、図 8(b) 内の歩行者は壁や車両からある程度離れた位置に存在するため、 R_o が他のフレームより高くなったと考えられる。また、図 8(c) では高く積み上げられた箱などの歩行者に類似した物体が存在するため、 R_f が低下したと考えられる。図 8(d) 内にも箱などの物体は多いものの、高く積まれておらず、また壁と一体化する位置に存在するために歩行者と判別しやすく、 R_f が他のフレームより高くなったと考えられる。

6. むすび


本発表では、歩行者検出器の車両周辺環境に対する信頼度の推定手法について提案した。正検出に関する信頼度、すなわち未検出の有無に関する信頼度について未検出が発生するしきい値を、誤検出に関する信頼度、すなわち誤検出の有無に関する信頼度について誤検出が発生するしきい値を用いた。信頼度の推定には、シーン全体を表現する全体特徴と、歩行者らしい、もしくは人工物らしい物体の存在具合を表現する歩行者特徴を用いた。そして、これらの特徴を用い、 ϵ -SVR によって推定器を構築した。実験の結果、未検出に関する信頼度を平均絶対誤差 5.1 で、誤検出に関する信頼度を平均絶対誤差 3.3 で推定できた。今後の課題として、未検出に関する信頼度推定器の精度向上が上げられる。

謝辞


本研究の一部は国立研究開発法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーションプログラム (名古屋 COI: 人がつながる “移動” イノベーション拠点)」の支援および、科学研究費補助金によって行われた。

参考文献

- (1) 福井 宏, 山下隆義, 山内悠嗣, 藤吉弘亘: [サーベイ論文] Deep Learning を用いた歩行者検出の研究動向, 電子情報通信学会技術研究報告, PRMU2016-121 (2016).
- (2) 川西康友ほか: 車載センシング技術の開発と ADAS、自動運転システムへの応用, chapter 6, 技術情報協会 (2017).
- (3) 城殿清澄, 渡邊章弘, 内藤貴志, 三浦 純: 高解像度レーザーレーダによる歩行者識別, 日本ロボット学会誌, Vol. 29, No. 10, p. 963–970 (2011).
- (4) Ogawa, T., Sakai, H., Suzuki, Y., Takagi, K. and Morikawa, K.: Pedestrian detection and tracking using in-vehicle LIDAR for automotive application, Proc. 2011 IEEE Intelligent Vehicles Symposium, p. 734–739 (2011).
- (5) Engelcke, M., Rao, D., Wang, D. Z., Tong, C. H. and Posner, I.: Vote3Deep: Fast Object Detection in 3D Point Clouds Using Efficient Convolutional Neural Networks, Proc. 2017 Int. Conf. on Robotics and Automation, p. 1355–1361 (2017).
- (6) Yamamoto, T., Shinmura, F., Deguchi, D., Kawanishi, Y., Ide, I. and Murase, H.: Efficient Pedestrian Scanning by Active Scan LIDAR, Proc. 2018 Int. Workshop on Advanced Image Technology, No. C4-2, p. 1–4 (2018).
- (7) Tatebe, Y., Deguchi, D., Kawanishi, Y., Ide, I., Murase, H. and Sakai, U.: Pedestrian Detection from Sparse Point-Cloud using 3DCNN, Proc. 2018 Int. Workshop on Advanced Image Technology, No. C4-4, p. 1–4 (2018).
- (8) 久徳遙矢, 川西康友, 出口大輔, 井手一郎, 加藤一樹, 村瀬 洋: 歩行者検出器の信頼度推定に関する初期検討, 自動車技術会 2017 年秋季大会 学術講演会 講演予稿集, p. 99–104 (2017).
- (9) 久徳遙矢, 川西康友, 出口大輔, 井手一郎, 加藤一樹, 村瀬 洋: LiDAR で計測した車両周辺環境の違いに応じた歩行者検出難易度の推定に関する初期検討, 電子情報通信学会技術研究報告, PRMU2017-184 (2018).
- (10) Liu, X., Zhao, G., Yao, J. and Qi, C.: Background Subtraction Based on Low-Rank and Structured Sparse Decomposition, IEEE Trans. on Image Processing, Vol. 24, No. 8, p. 2502–2514 (2015).
- (11) Schapire, R. E. and Singer, Y.: Improved Boosting Algorithms Using Confidence-rated Predictions, Machine Learning, Vol. 37, No. 3, p. 297–336 (1999).




(a) For oversights.




(b) For false detections.

Fig.7 Estimated reliabilities.



(a) Low reliability scene for oversights.

(b) High reliability scene for oversights.



(c) Low reliability scene for misdetections

(d) High reliability scene for misdetections

Fig.8 Examples of scenes with low and high reliabilities.