

高解像度ミリ波レーダによる駐車シーンの復元

秋田時彦*¹ 赤峰悠介*² 近藤勝彦*²
豊田工業大学*¹
(株) SOKEN*²

自動運転や ADAS には、厳しい屋外走行環境下での動作が要求されるため、耐環境性の高いミリ波レーダが必須であるが、分解能の制約から実現機能が限定されている。しかしながら、近年、ミリ波レーダの高解像度化と計算能力の向上が進んでおり、従来困難とされてきた車載イメージングレーダが実現可能になってきた。ここでは、実際の市街地の駐車シーンを、高解像度ミリ波レーダを用いて各種物体種別や形状まで含めて復元した実験結果について示す。蓄積反射マップからシーン推定する独自の深層学習ネットワークを構築し、セルごとの種別を推定した。実環境において識別可能な物体クラスに対する推定精度を定量化して、その限界を示した。

Reconstruction of parking scene using high-resolution millimeter-wave radar

Tokihiko Akita*¹ Yusuke Akamine*² Katsuhiko Kondo*²
Toyota Technological Institute*¹
SOKEN INC.*²

An environmentally resistant millimeter-wave radar is essential for automated driving. Recently, with the increasing resolution of millimeter-wave radar and computational power, it has become possible to realize an automotive imaging radar, which was previously considered difficult. Here, we present the experimental results in which parking scenes in actual urban areas were reconstructed using a high-resolution radar, including various object classes and shapes. An original deep learning network was constructed to estimate the class for each cell from accumulated reflection maps. The estimation accuracies for distinguishable object classes in real environments were quantified, and their limitations are shown.

Keyword: millimeter-wave radar, imaging radar, deep learning, parking scene

1. まえがき

自動運転や高度運転支援システムは、どのような天候や照明環境でも安全に動作することが求められて

おり、その環境で周辺物体を認識できるセンサが必要である。車載用環境認識は各種センサが用いられており、その得失は利用する電磁波の波長に依存す

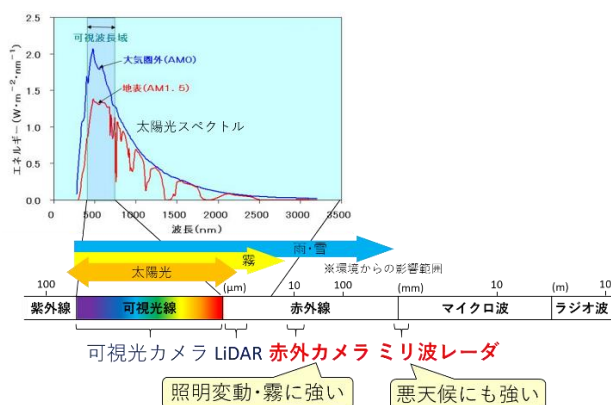


Fig. 1 車載環境認識センサの電磁波波長とその特性

る. Fig. 1 は可視光カメラ, LiDAR, 赤外カメラ, ミリ波レーダの利用する電磁波の波長と環境の外乱との関係を示した図である⁽¹⁾. ミリ波レーダの利用波長は, 太陽光波長や, 霧や雨, 雪の粒径より長いために, 影響を最も受けにくい. そのため, 自動運転などには必須のセンサである. しかし, 分解能が低くノイズなどの課題もあり, 主に障害物検出に機能が限定されている.

実現機能の拡張を目指し, 筆者は LSTM (Long Short Time Memory) を用いた物体識別機能の実現可能性を示した⁽²⁾. さらに, 高い推定形状精度が要求される駐車状況での応用実現に向けて, 独自に設計した CNN (Convolutional Neural Network) により駐車車両や縁石, フェンスの形状推定を含む駐車シーンの復元が高精度にできることを示した⁽³⁾. 本発表では, 複雑な実環境の駐車シーンにおいて, 障害物の種別及び形状推定がどこまで可能なのか定量的に示す.

2. 従来研究

近年, ミリ波レーダを用いた走行環境の認識に関する研究開発が幾つか行われている.

Fig. 2 に, ミリ波レーダの反射点群(図中左)に対して, 物体種別を推定する研究開発⁽⁴⁾の結果例を示す.



Fig. 2 深層学習による画像認識結果を用いた走行環境の推定結果




Fig. 3 レーダマップから走行環境を推定する SegNet




Fig. 4 SegNet による駐車シーンの推定結果

これはカメラ画像の物体認識結果(図中右上)を正解値として用い, 深層学習を学習し, 点群の種別を推定している. ここでは車両形状などは推定していない.

駐車シーンの復元に関する研究例⁽⁵⁾を説明する. これは Fig. 3 の通り, ミリ波レーダの反射信号を蓄積した画像に対して, 深層学習手法の一つである SegNet⁽⁶⁾を用いて, 車両や壁などを含む駐車シーンを復元したものである. その結果を Fig. 4 に示す. 左から反射蓄積画像, 正解シーン, 推定シーンであるが, 推定形状が崩れていることが分かる.

筆者が行った駐車シーン復元⁽³⁾の結果を Fig. 5 に示す. (a)が正解形状で, 種別として並列および縦列駐車車両, 縁石, フェンスを識別している. (b)が後述する独自の CNN による推定結果で, 精度良く各種物体の形状が復元されている. この評価条件では推定精度 97.47%であった. (c)に SegNet による結果を示すが, 推定形状は大きく崩壊している.

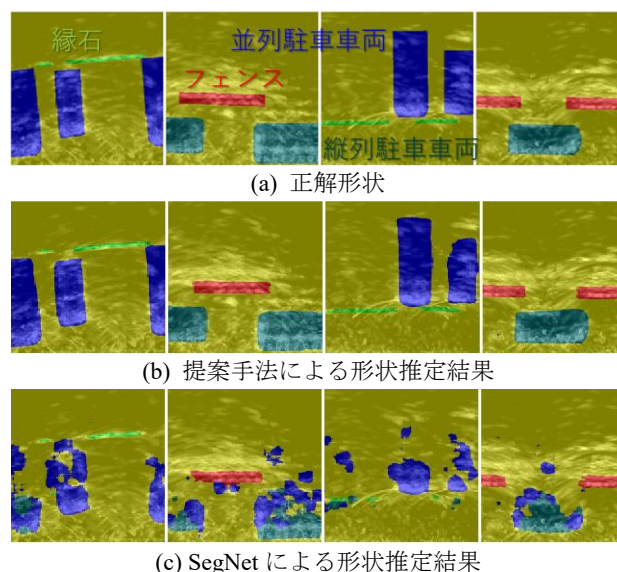


Fig. 5 独自 CNN による推定結果と SegNet との比較例

3. 駐車シーンの推定手法

本論文における駐車シーンの物体形状の推定手法について，データ生成を含めて説明する．

3-1 データ収集

Fig. 6 に、実験車に搭載したミリ波レーダと、正解値を生成するための LiDAR およびカメラを示す．ここでは、駐車シーン推定のためにセンサ群を横向きに設置し、右図の様に駐車シーンを走行しながら計測した．これにより、Fig. 7 の中央図の疎らなミリ波レーダ点群マップが計測される．これはユーシン社が開発した超解像アルゴリズム⁽⁷⁾を用




Fig. 6 計測実験システム構成と計測シーンイメージ





Fig. 7 ミリ波レーダ反射マップと蓄積グリッドマップ



LiDAR 点群と車両形状輪郭モデル 生成された正解形状

Fig. 8 LiDAR 点群を用いた駐車車両正解形状生成



レーダマップ上の領域枠 生成された正解形状

Fig. 9 手作業による静止物領域正解形状生成




Fig. 10 駐車シーンを復元する提案 CNN

いて計算している。左写真は、これに対応する駐車シーンのカメラ画像である。走行軌跡を補正しながら反射マップをグリッドマップに蓄積し、右図の密な反射グリッドマップを生成する。

3-2 正解値生成

反射グリッドマップと対応した駐車車両の正解形状マップを生成する方法を、Fig. 8 を用いて説明する。ミリ波レーダと同期して LiDAR 点群を計測し、ミリ波レーダと同様に走行軌跡を補正しながら点群を蓄積すると、左図の LiDAR 蓄積点群が得られる。ここでは、単層の回転式 LiDAR を用いたため、車両形状に対して隙間が多い点群しか得られなかった。そこで、近傍側を凸包によって曲線形状を抽出し、車両の側方および後方輪郭を矩形当て嵌めにより、右図の正解車両形状を生成した。ここで、車両後方位置などは計測できないため、車両ナンバープレートなどから車種を推定し、手作業で修正した。識別対象の物体種別として、並列および縦列、斜め駐車車両、縁石、フェンス、ポールなどの最大 10 クラスを選定した。車両形状以外の物体に関しては、形状が複雑で LiDAR を用いても真の形状は得られないので、レーダ蓄積反射マップに対して、カメラ画像を参照しながら Fig. 9 に示す様に手作業で反射領域を多角形で囲み、その中の一定反射強度の領域を抽出してその物体の正解形状とした。これと LiDAR 点群から生成した車両正解形状とを合成し、正解形状とした。

物体種別の反射強度グリッドマップサイズは、検知距離と必要領域、要求分解能から、400X400、1セル2cm四方で8mX8mとした。

3-3 推定ネットワーク

ミリ波レーダの蓄積グリッドマップを入力として、正解形状マップを推定する Fig. 10 の CNN を独自設計した．この構成は推定精度と計算能力を見ながら、ハイパーパラメータを調整し試行錯誤で決定した．ここで、損失関数 L_{we} を以下の式の各画素のクロスエントロピーとし、各クラス的面積で補正している．

$$L_{we} = -\frac{1}{N} \sum_{n=1}^N \sum_{i=1}^M w_i t_i^{[n]} \log(y_i^{[n]}) \quad (1)$$

ここで、 N はサンプル数、 M はクラス数、 w_i は各クラスの重みベクトル(各クラス頻度の逆数)、 $t_i^{[n]}$ はワンホットコーディング表現の正解値、 $y_i^{[n]}$ は推定スコアである。



Fig. 11 市街地の計測駐車シーン

4. 実環境における評価

4-1 市街地での実車計測データ

大学構内や民間施設，路上を含む市街地での駐車シーンを計測し，前章の方法に従って蓄積反射マップとその正解値のペアからなる評価データセットを生成した．ここでは全 1448 組のデータを作成した．そのサンプルシーンを Fig. 11 に示す．駐車車両の向きは，並列，縦列，斜めを含んでおり，これらも識別クラスとした．さらに駐輪場や店舗など駐車車両が含まれないシーンも計測した．

ここで，識別対象物の推定精度への影響を解析するため，識別クラス最大 10 種類に対して各種組合せでクラスをまとめて，Table. 1 に示す識別数とクラスの組合せにて評価を行った．

Table. 1 識別クラス数とクラスの組合せ

	駐 車 車 両			車 両 以 外						
識別数	並列	縦列	斜め	縁石	壁	車止め	柱	2輪車	植栽	その他
10	○	○	○	○	○	○	○	○	○	○
8	○	○	○	○			○	○	○	○
6	○	○	○	○					○	○
5	○	○	○	○						○
4	○	○	○	○						
3	○			○						○
2	○			○						

4-2 評価結果

評価データセットの 80%をランダムに抽出し，残りの 20%で精度を評価した．各 3 回評価し，平均した結果を Table. 2 に示し，Fig. 12 にグラフ描画した．

Table. 2 識別クラス数に対する推定精度 (%)

Number of class	All obstacles	Only car
10	96.65	
8	96.77	
6	96.84	
5	97.00	
4		99.12
3	96.70	
2		99.14

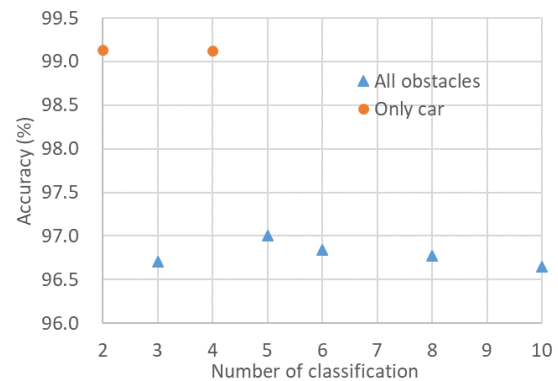



Fig. 12 識別クラス数に対する推定精度の関係


ここで，識別対象物が駐車車両のみ（グラフ中”Only car”）の場合と他の障害物も含む場（”All obstacles”）を分けて表示した．

この結果から，全体的には高い精度でこのような複雑な実環境でも多くの物体種別を識別できることが分かる．クラス数を増やしても精度の大きな低下は見られないことから，物体種別による推定精度の差異は少ないと考える．また，車両の様な滑らかな輪郭で強い反射がある物体に関しては，車両駐車向きを含み高精度に形状推定ができるが，その他の植栽に代表される反射が弱く形状が複雑なものが含まれていると推定精度は低下すると推察する．


評価サンプルを Fig. 13 に示す．各サンプルは，レーダ蓄積反射マップ（白色が強反射）上に，正解形状（左上図）と推定形状（右上図）を重ねた図，シーン写真（下図，レーダ検知範囲に対応した 3 枚）を含む．物体のクラスは(a)図のカラーバーで色分けしている．このサンプルから，各種物体に対して概ねクラス推定と形状が推定できていることが分かる．ただし，(a)図の車両間の車止めにに関して，一部識別ミスがあり，特に小さな物体に関しては完全ではない．この原因の一つとして，この例の様に正解値を付け忘れていることが挙げられる．(c)図でもボールの一部に正解値付けミス（正解値図中の手前中央付近）があるが，正しい推定が行われている．ここで，誤った正解値付けの修正を何度も行ったが，反射マ



(a) 斜め駐車シーン



(b) 駐輪シーン



(c) 店舗シーン (空車駐車場)

Fig. 13 正解値と推定結果の評価サンプル

Table. 3 識別クラス毎の推定精度(%)とIoU

	Accuracy	IoU
Non	0.97863	0.96569
CarP	0.94639	0.89643
CarS	0.91018	0.84077
CarA	0.88564	0.78324
Curb	0.59309	0.40764
Fence	0.76265	0.55138
CarStop	0.51713	0.37944
Pillar	0.46755	0.28811
TwCar	0.91051	0.70428
Plant	0.65373	0.38550




Fig. 14 各種駐車車両を含む評価サンプル

アップに対して状況によっては人でも正解クラスの付与が難しくミスが修正しきれず、課題の一つである。Table 3 に 10 クラスで識別し、最も精度が高かった結果における、各クラス毎の推定精度と IoU (Intersection over Union)を示す。この結果からも車両の推定精度は高く、小さな物体である柱や車止めの精度が低くなっていることが分かる。

他の評価サンプル 8 フレームを Fig. 14 に示す。紙面の関係上、対応するシーンの写真は省略している。駐車車両の向きやフェンス、縁石、ポール、植栽などの小さな物体についても概ね推定できている。車両の後部など形状が崩れているものがあるが、車両奥の形状は計測できず正解形状自体の精度の問題と反射の不安定性に起因すると考える。

次に、学習データの変動に対する頑健性を確認するために、データセットに対する学習データの割合を減少させて、精度が低下するか検証した。全データに対する学習データの割合を 80%から 50%, 20% と低下させた場合の、精度の変化を Fig. 15 に示す。学習率を減少させると精度は低下するが、50%程度

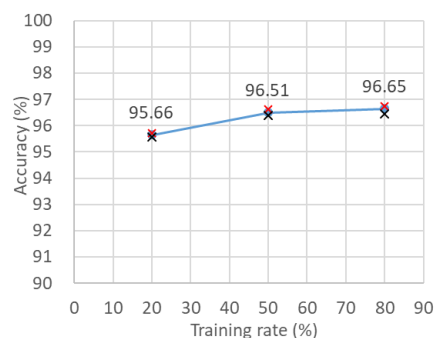


Fig. 15 学習率の推定精度への影響




Fig. 16 従来手法との精度比較

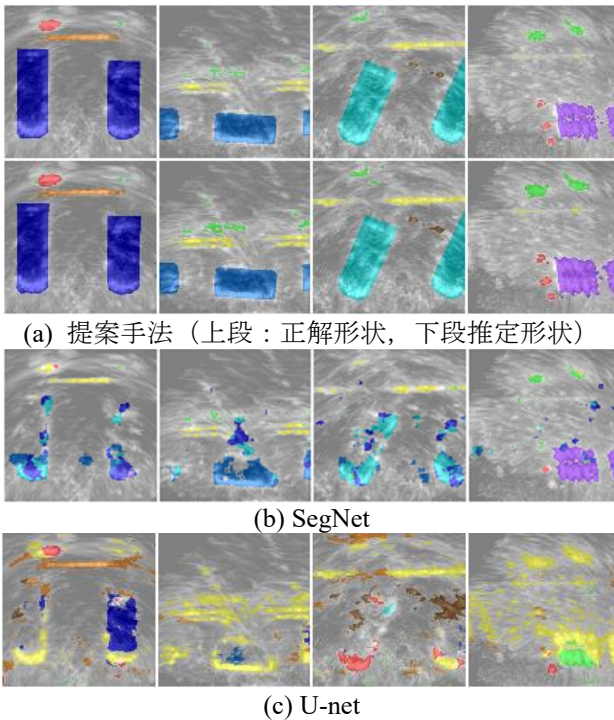


Fig. 17 従来手法との推定サンプル比較

まで減らしても大きな精度低下は見られない。20%まで減らすと約1%精度が低下するが、データのバリエーションなどに依存するので、定量的な説明は難しい。図中の×マークは最大値(赤)、最小値(黒)を示すが、大きなばらつきは無く、このデータセット内ではランダム抽出したデータの偏りからの影響は少ないと考える。

従来手法との比較結果を示す。Fig. 16に10クラス識別時のSegNetとU-netとの精度比較結果を図示する。ハイパーパラメータにより推定精度が左右されるため、これらは多大な時間を費やして調整を行った結果である。U-netでは学習が収束する確率が低く、収束した中で最も精度の良かった3回の平均を取った。提案手法に比べて大幅に精度が低下し、特にU-netは非常に精度が低かった。Fig. 17にその推定結果のサンプルを示す。従来手法はどちらも物体の形状が大きく崩壊しているが、特にU-netでは殆どクラスと形状を復元できていない。

5. まとめ

実際の市街地環境における駐車場にて計測したミリ波レーダの反射データから、独自に構築したCNNを用いて、10種類の物体種別とその形状を96.6%以上の精度で推定できることを示した。物体種別の分類数を減らしても精度に大差は無く、形状の単純で反射強度の強い駐車車両に関しては99%以上の推定精度が得られた。学習サンプルを50%に減らしても精度の大きな低下は無く、データの多少の変動には頑健であった。従来手法と比較しても独自構築したCNNの推定精度が高いことを示した。

課題としては、人手による正解値付けが難しく、正解値の信頼度が推定精度に影響を及ぼすことで、今後は、正解値付けの自動化やこれに関連して自己教師あり学習の活用などを検討していきたい。

謝辞

本研究は科研費(21K03985)の助成を受けたものである。実験用レーダを貸与いただいた(株)ユーシンと天野氏に感謝します。

参考文献

- (1) 秋田時彦: 自動車の画像認識 一車載カメラからパターン認識技術まで一, 科学情報出版, 2022.
- (2) T. Akita, et al.: Object Tracking and Classification Using Millimeter-Wave Radar Based on LSTM, The 22nd IEEE International Conference on Intelligent Transportation Systems, 2019.
- (3) 秋田 時彦, 他: ミリ波レーダによる深層学習を用いた駐車場環境の復元, 自動車技術会論文集, Vol. 52, No.1, pp. 113-118, 2021.
- (4) A. Shashua: CES2022 YouTube movie, <https://www.youtube.com/watch?v=QV7PGBfI49k>.
- (5) R. Prophet, et al.: Semantic Segmentation on Automotive Radar Maps, 2019 IEEE Intelligent Vehicles Symposium (IV), p. 676-683, 2019.
- (6) V. Badrinarayanan, et al.: Segnet: A deep convolutional encoder-decoder architecture for image segmentation. IEEE transactions on pattern analysis and machine intelligence, 39(12), p. 2481-2495, 2017.
- (7) 天野 義久, 他: ミリ波レーダに認識力 新原理で一気に超高解像に, 車載センサー三国志 第2部無線技術の革新, 日経エレクトロニクス 2018.03, 日経BP社, p. 25-30, 2018.