

マルチセンサフュージョンによるフリー スペース認識技術*

Development of Free Space Detection by Sensor Fusion

藤原 直広 Naohiro FUJIWARA
大門 真 Makoto OHKADO
寺二 存也 Ariya TERANI

Advanced Driver Assistance Systems (ADAS) are necessary for safe driving in complicated traffic environments. In some ADAS applications, it is necessary to recognize the free space area using multi sensors. In order to fuse and integrate the output of sensors, we need to handle the measurement conflicts between different sensors. Conventional methods such as Bayesian Filter increase the unknown or ambiguous information in the case of measurement conflicts between sensors. We propose an algorithm to decrease unknown information caused by sensors conflicts. We provide experimental results to compare the proposed method with conventional algorithms.

Key words :

Safety, Intelligent Vehicle, Road Environment Recognition, Sensor Fusion, Free Space Detection

1. まえがき

交通事故削減やドライバの運転負荷軽減への期待から、AEB (Autonomous Emergency Brake) や ACC (Adaptive Cruise Control) などの ADAS (Advanced Driver Assistance Systems) 機能の普及が進んでいる。さらに近年では、さらなる安全性と利便性の向上のため、LCA (Lane Change Assist) や自動バレー駐車システムのような、自車両周囲 360°の環境を監視し、ステアリングとアクセル・ブレーキ操作を行う、より高度な ADAS 機能が求められている。

このような機能では、従来求められていた自車両前方の環境認識に加え、自車両周囲の走行可能領域 (フリースペース) 認識が必要となる。ここで、フリースペース認識では主に車載センサが用いられるが、単一

のセンサのみでは、センサの持つ長短により認識のロバスト性が低下してしまう。例えば、画像センサでは、車両や標識などの物体識別が可能であるのに対し、逆光や雨天時に認識精度が低下する。一方、ミリ波レーダは天候変化にロバストだが、電波反射が弱い物体を検出することが難しい。このような各センサの欠点を補うために、複数の異種センサを組み合わせるセンサフュージョン技術が活用されている^{1) 2)}。センサフュージョンにより、誤差を含むセンサ出力同士を正しく統合することで、ロバストなフリースペース認識が実現できる。

フリースペースを表現する手法の一つとして、Occupancy Grid Map (OGM)^{3) 4)} が挙げられる。OGM はセンサ間で大きさが共通である Grid Map を用いることで、複数センサからの出力を容易に統合す

ることができる。しかしながら、従来の OGM 生成アルゴリズムでは、センサ出力が競合した際、互いの出力が真逆となるため、フリースペースであるか否かを判別することができない。このような領域は未知領域と呼ばれる。この未知領域が多く生じると正しく周辺環境を表現できないため、機能の誤作動・不作動の要因となる。

そこで本稿では、出力競合時において未知領域を低減させるフリースペース認識技術の開発を目的とする。具体的には、センサ信頼度による重みづけと Dempster-shafer 理論⁵⁾⁻⁷⁾ を組み合わせることで課題を解決する。2章で、OGM 生成アルゴリズムとして一般に用いられる Bayesian Filter について述べ、3章で従来技術の課題を解決する提案手法について述べる。4章では、試験車両を用いた性能評価試験により、提案手法の有効性を検証した結果について示す。

2. Occupancy Grid Map

2.1 Occupancy Grid Map

OGM は、領域を格子状に分割し、各格子 (セル) に割り当てられた確率変数で占有/フリーを判別する手法である (Fig. 1)。OGM は複数センサ出力の統合の容易さや、Path Planning などの経路探索アルゴリズムとの親和性の高さから、周辺環境を表現する代表的な手法となっている⁸⁾⁻¹⁰⁾。OGM 生成アルゴリズムでは、与えられたデータを基にマップの事後確率を以下の通り算出する。

$$p(m|z_{1:t}, x_{1:t}) \quad (1)$$

m はマップ、 $z_{1:t}$ は時刻 t までのセンサによる全ての観測値、 $x_{1:t}$ は時刻 t までの自車両位置の軌跡を表す。ここで、 m の取り得る状態数はマップ上のセルの個数に依存する。例えば 100×100 セルのマップの場合、各セルは占有/フリーの2つの状態を持つため、 m の次元は $2^{100 \times 100}$ となる。このような非常に高次元な空間に対して式 (1) の事後確率を推定することは非常に困難である。そのため、各セル同士は独立であると仮定し、マップ m の事後確率を推定する問題を、各セルの事後確率を推定する問題へと置き換える³⁾。このとき、

各セルの事後確率は、

$$p(\mathbf{m}_i|z_{1:t}, x_{1:t}) \quad (2)$$


と表される。 \mathbf{m}_i はインデックス i を持つセルを表す。マップ m は各セル \mathbf{m}_i の集合であり、

$$m = \{\mathbf{m}_i\} \quad (3)$$

と表現できる。このとき式 (2) を用いて、マップ m の事後確率は以下の通り算出される。

$$p(m|z_{1:t}, x_{1:t}) = \prod_i p(\mathbf{m}_i|z_{1:t}, x_{1:t}) \quad (4)$$

推定された事後確率に閾値を設定することで占有/フリーが判別される。



0.0 Probability 1.0

Fig.1 Occupancy Grid Map

2.2 Bayesian Filter による事後確率の推定

式 (2) の事後確率を推定する方法として、ベイズ理論に基づく Bayesian Filter がよく用いられている^{11) 12)}。Bayesian Filter では、式 (2) の事後確率を対数オッズにより以下のように表す。

$$l_{t,i} = \log \frac{p(\mathbf{m}_i|z_{1:t}, x_{1:t})}{1 - p(\mathbf{m}_i|z_{1:t}, x_{1:t})} \quad (5)$$

対数オッズで表現することによって、確率計算で生じる 0 もしくは 1 付近の値の不安定さを回避することができる。Bayesian Filter では、各セル \mathbf{m}_i に対して繰り返し計算を行うこと対数オッズを更新する。

* (社)自動車技術会の了解を得て、「自動車技術会論文集」51巻,2号,p.328-332より一部加筆して転載

$$l_{t,i} = l_{t-1,i} + \log \frac{p(\mathbf{m}_i|z_t, x_t)}{1 - p(\mathbf{m}_i|z_t, x_t)} - \log \frac{p(\mathbf{m}_i)}{1 - p(\mathbf{m}_i)} \quad (6)$$

$p(\mathbf{m}_i)$ は各セルの事前確率を表す。

2.3 センサフュージョンにおける Bayesian Filter の課題

Bayesian Filter は、センサ出力毎に $p(\mathbf{m}_i|z_t, x_t)$ を推定することで、センサフュージョンへの適用が可能となる。このとき事後確率は以下の通り逐次更新される。

$$l_{t,i} = \sum_n^N l_{t,i,n} \quad (7)$$

ここで、 N は統合に用いるセンサ数を表す。

複数センサを用いる時、あるセンサからの出力は占有、一方のセンサからの出力はフリーとなる状況が起こり得る。このように各センサ出力が競合するとき、Bayesian Filter により推定される事後確率は 0.5 付近の値となる。これは未知領域と判別され、フリースペースか否か正しく認識できないことを意味する。よって、この未知領域が多く生じるとフリースペース認識性能が低下してしまう。

3. 提案手法

本稿では、未知領域を低減させるために、センサ信頼度および Dempster-Shafer 理論⁵⁾⁻⁷⁾ を組み合わせる手法を提案する。次節以降にセンサ信頼度の設計、および Dempster-Shafer 理論に関して述べる。

3.1 センサ信頼度の設計

式(7)より、Bayesian Filter ではセンサ出力を統合する際、各センサを同等に扱っている。しかしながら、センサ種別などによって各センサ出力の信頼度は異なると考えられる。そこで本稿では、センサ出力ごとに信頼度を設計し、これを OGM の事後確率更新に活用する。これにより、信頼度の高いセンサほど事後確率への影響が大きくなるため、出力競合時でも未知領域が生じにくくなる。なお、本稿では、利用するカメラ、ミリ波レーダ、ソナーに対して計測誤差評価試験を行

い、その結果を基に3種類の信頼度を設計した。評価試験では、各センサ及び高精度レーザスキャナ (FARO 社製 FocusS 150) を用いて目標ターゲット位置を計測し、距離・方位それぞれの計測誤差を算出した。センサの距離・方位誤差が小さいほど信頼度が高いと仮定し、評価結果を基に信頼度モデルを設計した。なお、本稿では各センサで共通の信頼度モデルを用いている。各信頼度の定義について以降に示す。

(1) 検出距離における信頼度

$$w_R = \alpha r + \beta \quad (8)$$

$$R_{min} < r < R_{max}$$

r は検出距離、 α, β は定数、 R_{min}, R_{max} はそれぞれ、各センサの最小/最大検出距離を表す。

(2) 検出方位に基づく信頼度

$$w_\theta = \exp(-k \times \theta^2) \quad (9)$$

$$\theta_{min} < \theta < \theta_{max}$$

θ は検出方位、 k は定数、 $\theta_{min}, \theta_{max}$ はそれぞれ、各センサの最小/最大検出方位角を表す。

(3) 誤差共分散に基づく信頼度

$$w_\sigma = \frac{1}{\eta v} \quad (10)$$

v はセンサの誤差共分散、 η は正規化項を表す。

なお、信頼度モデルのパラメータである α, β 及び k に関しては、それぞれセンサ毎に異なる値を用いている。各信頼度を対数オッズにより統合し、センサの信頼度を以下のように推定する。

$$\log w = \log \frac{p(w_r)}{1 - p(w_r)} + \log \frac{p(w_\theta)}{1 - p(w_\theta)} + \log \frac{p(w_\sigma)}{1 - p(w_\sigma)} \quad (11)$$

推定されたセンサ信頼度 w を用いて、OGM の事後確率を更新する。

3.2 Dempster-Shafer 理論

Dempster-Shafer 理論⁵⁾⁻⁷⁾ は、一般的な確率論のように全体集合 θ の各事象に確率を割り当てるのではなく、 θ の部分集合に対して確率を割り当てる理論体系

である。これを OGM に適用すると、各セルは占有 (O) とフリー (F) の事象を持つことから、全体集合 θ は

$$\theta = \{O, F\} \quad (12)$$

のように表され、この全体集合 θ の部分集合は、

$$2^\theta = \{\emptyset, O, F, \{O, F\}\} \quad (13)$$

となる。ここで、 ϕ は空集合、 $\{O, F\}$ は未知領域を表す。Dempster-Shafer 理論ではこの部分集合の各要素に確率が割り当てられる。つまり、占有/フリー/未知領域の確率がそれぞれ明示的に算出されることを意味する。これにより、判別結果が閾値に依存する Bayesian Filter に対して、Dempster-Shafer 理論ではそれぞれの確率を比較することで各セルの状態を判別できる。

部分集合の各要素に割り当てられる確率は、以下の条件を満たす関数 m によって表される。

$$m(\emptyset) = 0$$

$$0 \leq m(A) \leq 1 \quad (14)$$

$$\sum_{A \subseteq \theta} m(A) = 1$$

$m(A)$ は部分集合の各要素 A に割り当てられた確率である。Dempster-Shafer 理論による OGM の事後確率は、関数 m を用いて以下のように逐次的に更新される。

$$m_{1:t}(A) = \begin{cases} \sum_{X,Y \in 2^\theta | X \cap Y = A} m_t(X) \cdot m_{1:t-1}(Y) & , A \neq \emptyset \\ 1 - \sum_{X,Y \in 2^\theta | X \cap Y = \emptyset} m_t(X) \cdot m_{1:t-1}(Y) & , A = \emptyset \\ 0 & , A = \emptyset \end{cases} \quad (15)$$

3.3 センサ信頼度と Dempster-Shafer 理論の統合

3.1 節で定義したセンサ信頼度と Dempster-Shafer 理論を組み合わせる方法について述べる。センサ信頼度 w を考慮したときの各事象に対する確率 $m^w(A)$ を以下のように算出する。

$$m^w(A) = \begin{cases} w \cdot m(A) & , \forall A \subset \theta \\ 1 - \sum_{B \subset \theta} w \cdot m(B) & , A = \theta \end{cases} \quad (16)$$

各センサに対して推定された $m^w(A)$ を統合することで、OGM の事後確率を更新する。

一般に、各センサ出力を統合する際、センサ毎に OGM を生成し、OGM 同士を統合する方法が用いられる⁸⁾。しかしながら、この方法では用いるセンサの数だけ OGM を生成する必要があるため、センサ数が増加するとメモリ負荷および計算量が増加してしまう。そこで本稿では、センサ毎に OGM を作らず、センサ間で共通の OGM を持ち、これを各センサ出力により逐次更新する方法をとる (Fig. 2, Fig. 3)。これにより、効率的に OGM の更新を行うことが可能となる。この時、OGM の事後確率は以下のように更新される。

$$m_{1:t}(A) = \begin{cases} \sum_{X,Y \in 2^\theta | X \cap Y = A} m_{t,s_i}^w(X) \cdot m_{1:t-1}(Y) & , A \neq \emptyset \\ 1 - \sum_{X,Y \in 2^\theta | X \cap Y = \emptyset} m_{t,s_i}^w(X) \cdot m_{1:t-1}(Y) & , A = \emptyset \\ 0 & , A = \emptyset \end{cases} \quad (17)$$

$m_{t,s_i}^w(A)$ は時刻 t におけるセンサ s_i の確率を表す。式(17)より、出力競合時においても、 $m_{t,s_i}(\{O, F\}), m_{1:t-1}(\{O, F\})$ の確率が小さければ、事後確率 $m_{1:t}(\{O, F\})$ は小さくなる。そのため、提案手法では Bayesian Filter に比べ未知領域と判別されにくくなる。

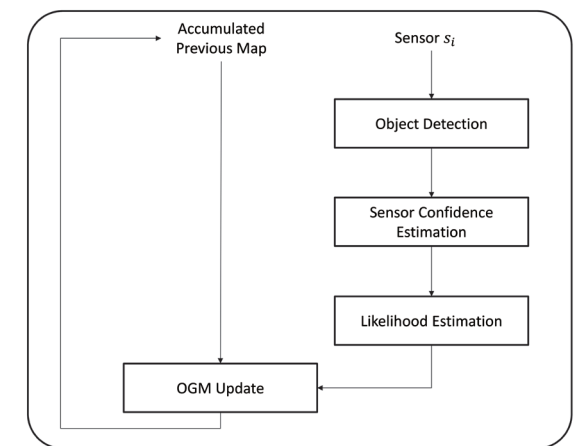


Fig. 2 Algorithm Flow Chart




Fig. 3 Update OGM with different sensors' timestamp

4. 提案手法の性能評価

本手法の有効性を検証するため、複数センサが搭載された試験車両を用いて性能評価を行った。比較手法として Bayesian Filter と、Logarithmic Independent Opinion Pool (LIOP)⁵⁾ と呼ばれる各センサ出力の重みを考慮した Bayesian Filter を用いる。LIOP では、3.2 節で定義したセンサ信頼度を重みとして利用する。本評価では、比較手法に比べ、提案手法の認識性能が低下することなく、未知領域が減少していることを検証する。

4.1 試験車両

使用した試験車両のセンサ構成を Fig. 4 に示す。自車両周囲 360° 認識可能なセンサ構成となっており、これらのセンサで取得した走行データを性能評価に用いた。なお、提案手法の評価のため、高精度 Lidar (Velodyne 社製 HDL-32e) を真値センサとして用いた。




Fig. 4 Sensor setup of test vehicle

4.2 評価条件と評価指標

Fig. 5 に評価シーンを示す。これらは車両間のすり抜け (シーン 1) 及び駐車スペース認識 (シーン 2) を模擬しており、いずれも自車両周囲のフリースペース認識が必要となるシーンである。また、センサ間の出力を競合させるため、複数センサで検出可能な位置にターゲット車両を配置した。

性能評価指標として、未知領域セル数とフリースペース認識性能を設定した。それぞれの評価指標について Fig. 6 に示す。未知領域セル数に関しては、試験車両スタート位置の前方領域を評価領域とし、評価領域内で未知領域と誤出力されたセル数を比較する。また、フリースペース認識性能に関しては、高精度 Lidar の出力と比較し、ターゲット車両の横方向・縦方向の距離誤差 (Xerr1, Xerr2, Yerr1, Yerr2) を評価する。なお、Grid Map のサイズを 200m × 200m、各セルのサイズを 0.25m とし、自車両の走行速度を 10km/h とした。セルサイズに関しては、本評価で用いたセンサのうち、距離分解能が最大であるセンサを基準に設定した。

距離誤差 (Xerr1, Xerr2, Yerr1, Yerr2) を評価する。なお、Grid Map のサイズを 200m × 200m、各セルのサイズを 0.25m とし、自車両の走行速度を 10km/h とした。セルサイズに関しては、本評価で用いたセンサのうち、距離分解能が最大であるセンサを基準に設定した。

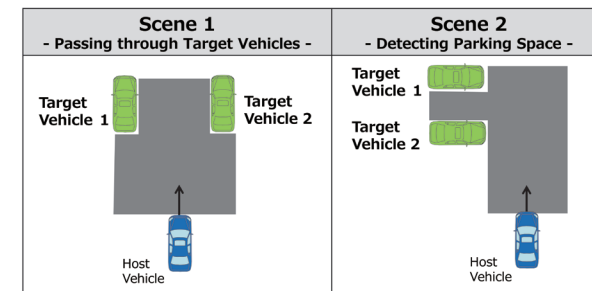


Fig. 5 Evaluation scene

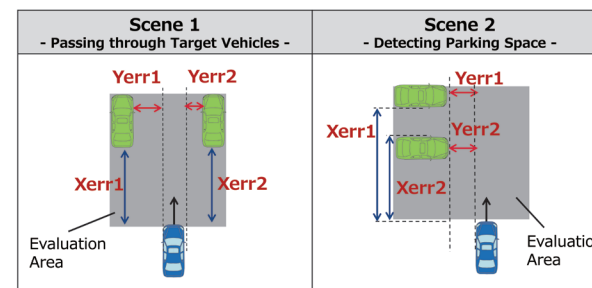


Fig. 6 Parameters for Evaluation

4.3 評価結果

各評価シーンでの未知領域セル数に関する評価結果を Table 1 に示す。結果は 30 回の試験における、未知領域と誤出力されたセル数の平均値を表している。同表より、比較手法に比べ提案手法の未知領域セル数が大幅に減少していることが分かる。LIOP においても未知領域が多く発生していることから、センサ信頼度の活用だけでなく、Dempster-Shafer 理論も組み合わせることで未知領域の低減が実現できることが分かる。また、シーン 2 における、提案手法と LIOP の OGM 出力例を Fig. 7 に示す。同図の赤い領域が未知領域と出力されたセルを表す。これより、LIOP ではターゲット車両間に未知領域が多く生じており、正しくフリースペースが認識できていないことが分かる。次に、フリースペース認識性能に対する評価結果を Table 2 に示す。結果はターゲット車両における平均距離誤差を表しており、提案手法の認識性能が比較手法と同等以上であることが分かる。

Table 1 Average number of cells detected as unknown area

	Proposed Method	LIOP	Bayesian Filter
Scene 1	0.50	29.90	30.60
Scene 2	2.25	16.57	16.38

Table 2 Average error for free space: (a) Scene 1, (b) Scene 2

(a)

	Proposed Method	LIOP	Bayesian Filter
Xerr 1 [m]	0.73	1.21	1.22
Xerr 2 [m]	0.25	0.78	0.90
Yerr 1 [m]	0.32	0.55	0.55
Yerr 2 [m]	0.48	0.50	0.50

(b)

	Proposed Method	LIOP	Bayesian Filter
Xerr 1 [m]	0.54	0.67	0.64
Xerr 2 [m]	0.23	0.24	0.35
Yerr 1 [m]	0.21	0.31	0.32
Yerr 2 [m]	0.30	0.35	0.35

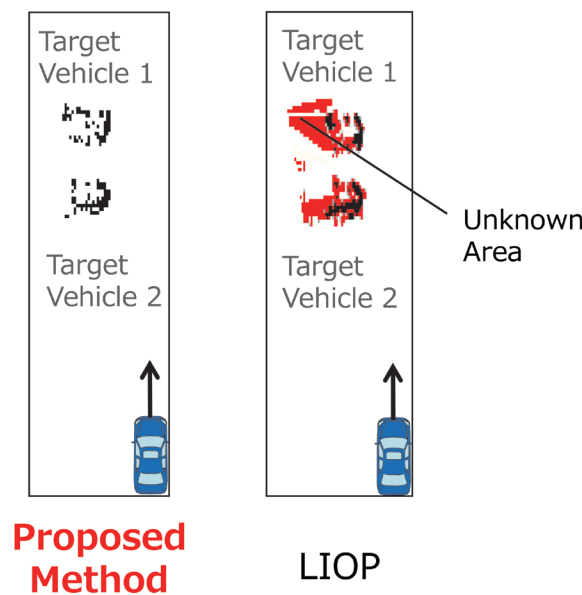


Fig. 7 Example: Output of OGM at Scene 2

5. むすび


本稿では、センサ出力競合時に対応するため、センサ信頼度と Dempster-Shafer 理論を組み合わせた手法を提案し、複数センサを搭載した試験車両による評価により、手法の有効性を検証した。評価試験の結果、本手法はセンサ間の出力競合が起こり得るシーンにおいて、Bayesian Filter 及び LIOP に比べ、認識性能が同等かつ、出力される未知領域が少ないことを示した。

今後の課題として、センサ信頼度の精度向上や、一般道など複雑交通環境下での性能評価などが挙げられる。

参考文献

- 1) H. P. Moravec : Sensor fusion in certainty grids for mobile robots, AI magazine, p.61-74, (1988)
- 2) C. Coue, C. Pradalier, C. Laugier, Th. Fraichard, and P. Bessiere, : Bayesian occupancy filtering for multi-target tracking: an automotive application, International Journal of Robotic Research, Vol.25, no.1, p.19-30, January (2006)
- 3) S. Thrun, W. Burgard and D. Fox, : Probabilistic Robotics, Commun. ACM, Vol.45, no.3, (2002), 480p
- 4) Sahdev, R, : Free Space Estimation using Occupancy Grids and Dynamic Object Detection, (2017)
- 5) P. G. C. Fernandez : Grid-Based Multi-Sensor Fusion for On-Road Obstacle Detection: Application to Autonomous Driving, (2015).
- 6) D. Pagac, E. Nebot, and H. Durrant-Whyte, : An evidential approach to map-building for autonomous vehicles, Transactions on Robotics and Automation, vol. 14, no. 4, p. 623-629, (1998)
- 7) R. R. Murphy, : Dempster-Shafer theory for sensor fusion in autonomous mobile robots, IEEE Trans. Robotics and Automation, vol. 14, pp. 197-206, (1998)
- 8) A. Elfes, : Using occupancy grids for mobile robot perception and navigation, IEEE Computer, vol. 22, no. 6, p.46-57, (1989)
- 9) G. Tanzmeister, D. Wollherr, M. Buss, : Grid-based multi-road-course estimation using motion planning, Transactions on Vehicular Technology, vol. 65, no. 4, pp. 1924-1935, (2016)
- 10) M. Konrad, D. Nuss, and K. Dietmayer, : Localization in digital maps for road course estimation using grid maps, Intelligent Vehicles Symposium. IEEE, pp. 87-92, (2012)
- 11) P. Stepan, M. Kulich, and L. Preucil, : Robust data fusion with occupancy grid, Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions, Vol. 35, no.1, p. 106-115, (2005)
- 12) J. Adarve, M. Perrollaz, A. Makris, and C. Laugier, : Computing occupancy grids from multiple sensors using linear opinion pools, IEEE International Conference on Robotics and Automation, p.4074-4079, (2012)

著者



藤原 直広

ふじわら なおひろ

AD&ADAS システム開発部
センサフュージョンによる周辺環境認識の
技術開発に従事



大門 真

おおかど まこと

AD&ADAS システム開発部
センサフュージョンによる周辺環境認識の
技術開発に従事



寺二 存也

てらに ありや

AD&ADAS システム開発部 博士(工学)
センサフュージョンによる周辺環境認識の
技術開発に従事