

研究速報

歩行者属性と運転スキルを考慮したリスクポテンシャル関数による歩行者に対する安全マージン予測

前川 大和^{†a)} (正員) 平山 高嗣^{††,†††} (正員)
 川西 康友^{†,††††} (正員: シニア会員) 出口 大輔[†] (正員)
 劉 海龍[†] 井手 一郎^{†,††††} (正員: シニア会員)
 村瀬 洋[†] (正員: フェロー)

Safety Margin Prediction for Pedestrians Using Risk Potential Function Considering Pedestrian Attributes and Driver Skill

Yamato MAEKAWA^{†a)}, Takatsugu HIRAYAMA^{††,†††}, *Members*,
 Yasutomo KAWANISHI^{†,††††}, *Senior Member*, Daisuke DEGUCHI[†], *Member*,
 Hailong LIU[†], *Nonmember*, Ichiro IDE^{†,††††}, *Senior Member*, and
 Hiroshi MURASE[†], *Fellow*

[†]名古屋大学大学院情報学研究科, 名古屋市

Graduate School of Informatics, Nagoya University, Furo-cho, Chikusa-ku, Nagoya-shi, 464-8601 Japan

^{††}名古屋大学未来社会創造機構, 名古屋市

Institute of Innovation for Future Society (MIRAI), Nagoya University, Furo-cho, Chikusa-ku, Nagoya-shi, 464-8601 Japan

^{†††}人間環境大学人間環境学部, 岡崎市

Faculty of Human Environment, University of Human Environments, Motojuku-cho, Okazaki-shi, 444-3505 Japan

^{††††}理化学研究所情報統合本部ガーディアンロボットプロジェクト, 京都府
 Guardian Robot Project, R-IH, RIKEN, Seika-cho, Soraku-gun, 619-0288 Japan

^{†††††}名古屋大学数理・データ科学教育研究センター, 名古屋市

Mathematical and Data Science Center, Nagoya University, Furo-cho, Chikusa-ku, Nagoya-shi, 464-8601 Japan

a) E-mail: yamato.maekawa63@gmail.com

DOI:10.14923/transfunj.2021JAL2005

あらまし 本論文では、電動車いすのより安全な自動運転のための経路計画を目的として、歩行者属性と運転スキルを考慮したリスクポテンシャル関数を運転データから推定する手法を提案し、それらによる歩行者に対する電動車いすの安全マージンの違いを明らかにする。

キーワード リスクポテンシャル関数, 電動車いす, 歩行者属性, 運転スキル, 安全マージン

1. まえがき

近年, MaaS (Mobility as a Service) への期待や超高齢化社会における新たな移動手段としてパーソナルモビリティの需要が増加している。そのなかでも高齢者を含めて誰でも安心して乗れるような、座ったまま移動できる電動車いすが注目されている。その事故防止や新しいサービスの提供を目的として、電動車いすの自動運転に関する研究開発 [1] が進んでいる。既に自動車に対してはポテンシャル場を用いた軌道生成が試みられており [2], 歩行者との衝突といったリスクの大きさを表すリスクポテンシャル関数の値が低い経路を




図1 リスクポテンシャル関数の例
 Fig. 1 Example of the risk potential function.

選択することで、安全に走行できると考えられる。本論文では、電動車いすの自動運転のために、図1に示すようなリスクポテンシャル関数の推定手法を提案する。リスクポテンシャル関数とは、他者との衝突など交通リスクの大きさを位置の関数として表現したものである。自動車を運転する際のリスクポテンシャル関数に関する従来研究では、他車両や歩行者、障害物など、物体の大まかな種類に応じたリスクポテンシャル関数の定義にとどまっている [2], [3]。しかし、電動車いすのように歩道を走行するパーソナルモビリティでは、歩行者との距離が近く、このような定義では不十分であり、歩行者に関して説明性が高いリスクポテンシャル関数が必要である。本論文では、「歩きスマホ」などの歩行者属性や運転者のスキル（以下、運転スキル）によって歩行者と衝突するリスクが異なると考え、これらに応じた歩行者のリスクポテンシャル関数の作成を目的とする。

歩行者属性として、年齢や性別、服装、所持物、行動などがあるが、歩行者が自転車に気づいているか否かは、その歩行者がもつリスクに密接に関わる [4]。本論文では、自転車への気づきに関係する歩行者属性に着目する。自転車への気づきを妨げる要因として視覚的要因と聴覚的要因が考えられる。本論文では、それぞれに最も強く影響すると考えられる「歩きスマホをしている歩行者」と「ヘッドホンをしている歩行者」に着目する。前者は近年の社会問題にもなっている。また、自転車に気づいているか運転者側から判別できない「サングラスをかけている歩行者」にも着目する。なお、複数人で会話しているような歩行者同士がインタラクションしている場合は、関与する人数によっても状況が変わるため、本論文では歩行者間での影響を取り除くために、各歩行者で独立して設定できる属性




図2 電動車いすと2人の歩行者がすれ違う状況の例

Fig. 2 Example of a situation where an electric wheelchair and two pedestrians pass each other.

を対象とする。

また、運転スキルを考慮したリスクポテンシャル関数を推定し、運転スキルによって各歩行者に対する安全マージンがどのように変化するかを明らかにする。運転スキルが高いリスクポテンシャル関数を自動運転へ応用することで熟練者の運転を実現できると考えられる。

本論文の貢献は、以下に要約される。

- 歩行者属性と運転スキルを考慮したリスクポテンシャル関数の推定手法を提案。
- 歩行者属性と運転スキルによる歩行者の衝突リスクの違いを分析。

2. 提案手法

本論文では、まず歩行者属性と運転スキルを考慮したリスクポテンシャル関数を推定する手法を提案する。そして、推定したリスクポテンシャル関数を用いて、リスクの対象から安全と考えられる距離を表す安全マージンを予測する。

2.1 リスクポテンシャル関数

電動車いすは歩道を走行するため、歩行者とのすれ違いが頻発すると考えられる。1人の歩行者や互いに歩いている歩行者とすれ違う場合には、空いている方に寄れば良いが、複数の歩行者と同時にすれ違う場合には、各歩行者に対する安全マージンに注意を払う必要があり、自車両への気づきに関係する歩行者属性を考慮することが重要である。これらの歩行者属性と安全マージンとの関係は明らかでないため、本論文では、複数の歩行者と同時にすれ違う状況における歩行者属性と安全マージンの関係を明らかにする。

上述のような状況において自車両に影響を及ぼす要素は、歩行者と道路境界の二つであると考えられる。図2のように、電動車いすと歩行者2人の位置がx軸方向に一直線上にある場合、図3に示すような1次元のポテンシャル場で考えることができる。




図3 図2の状況で推定される1次元ポテンシャル場

Fig. 3 One-dimensional potential field estimated in the situation shown in Fig. 2.

まず、歩行者が及ぼすリスクを考える。歩行者のリスクポテンシャル関数 R_p を以下の式で表現する。

$$R_{p_j}(x; \sigma^2) = \exp\left(-\frac{(x - x_j)^2}{2\sigma^2}\right) \quad (1)$$

ここで x_j は、歩行者 j の位置を表す。次に、歩行者属性と運転者の運転スキルを用いて σ^2 を以下のように定義する。

$$\sigma^2 = \sigma_p^T \mathbf{s}_j + k \cdot \text{skill}^i \quad (2)$$

$$\sigma_p^T = (\sigma_N^2, \sigma_{SP}^2, \sigma_{SG}^2, \sigma_{HP}^2, \sigma_{SP+HP}^2)^T \quad (3)$$

ここで、 σ_p^T は歩行者属性 p に対応する分散を並べたベクトル、 k は運転スキルの影響度を表し、いずれも次節で推定するパラメータである。また、 \mathbf{s}_j は歩行者 j の属性を示す One-hot vector である。 σ_N^2 、 σ_{SP}^2 、 σ_{SG}^2 、 σ_{HP}^2 、 σ_{SP+HP}^2 は、それぞれ、通常 (N: Normal)、歩きスマホ (SP: SmartPhone)、サングラス (SG: SunGlasses)、ヘッドホン (HP: HeadPhone)、歩きスマホ+ヘッドホン (SP+HP: SmartPhone+HeadPhone) の属性をもつ歩行者のリスクポテンシャル関数の分散である。 skill^i は運転者 i の運転スキルである。

本論文では、運転スキルを評価するために、以下に示すような Huang らが定義した電動車いす運転者の運転スキルの指標 [5] を用いる。

- 速度に関する指標：平均速度
 - 速度制御に関する指標：速度の標準偏差
 - 方向制御に関する指標：向心加速度の標準偏差
- 上記三つの指標を運転者ごとに計算し、速度平均が大きいほど運転スキルが高くなるように、速度と向心加速度の標準偏差が小さいほど運転スキルが高くなるように $[0, 1]$ の範囲で正規化する。そして、これらの平均として運転スキル値 skill^i を定義する。

次に、道路境界が及ぼすリスクを考える。道路境界




図4 実験で使用した電動車いす (WHILL Model CR) と実験環境

Fig. 4 Experimental electric wheelchair (WHILL Model CR) and experimental environment.

に関するリスクポテンシャル関数 R_r を以下のように定義する。道路外に行くと、壁など他の障害物に衝突するリスクが高まるため、道路中央で最小に、道路境界や道路外に行くほど値が大きくなるように設計する。

$$R_r(x; a) = ax^2 \quad (4)$$

ここで、 a は道路境界に関するリスクポテンシャル関数の比例定数であり、次節で推定するパラメータの一つである。

2.2 リスクポテンシャル関数のパラメータの推定

最終的に、運転データから、リスクポテンシャル関数のパラメータ σ_p^2 , a , k を勾配降下法で最適化する。運転データには推定した運転スキル、すれ違い時の電動車いすの位置、歩行者の位置と歩行者属性が含まれる。

2.3 安全マージン予測

安全マージンの予測では、運転スキルとすれ違い時の歩行者の位置、歩行者属性を入力として、電動車いすの位置を出力することで歩行者に対する安全マージンを予測する。そのために、各位置におけるリスクの総和をリスクポテンシャル関数から算出し、最小となる位置 \hat{x} を出力する。

$$\hat{x} = \arg \min_x R(x; \sigma_p^2, a, k) \quad (5)$$

$$R(x; \sigma_p^2, a, k) = \sum_j R_{p_j}(x; \sigma_p^2) + R_r(x; a) \quad (6)$$

3. 実験

安全マージン予測を評価するための運転データを収集し、それを用いて評価実験を行った。

3.1 データ収集

本実験では、20代～40代（平均：39.2歳、標準偏



(a) 道路の両端に分かれて歩行 (b) 道路の中央を並んで歩行

図5 2人の歩行者の歩行パターン (赤丸が歩行者を示す)

Fig. 5 Walking pattern of two pedestrians (Red circles represent the pedestrians).

差：7.74歳）の男女10人の参加を得て、運転行動を計測する。また本実験では、図4に示す電動車いすを使用する。実験参加者は、パイロンで示された区間を電動車いすで走行し、実験協力者の2人の歩行者とすれ違う。歩行者は、電動車いすの移動開始位置とは反対側のパイロンから、電動車いすと同時に歩行を開始する。図5のように、歩行者の歩行パターンとして以下の2種類を設定する。

- 歩行者2人が道路の両端に分かれて歩行
- 歩行者2人が道路の中央を並んで歩行

また、式(3)で扱う5種類の歩行者属性を設定する。

- 通常の歩行者
- 歩きスマホをしている歩行者
- サングラスをかけている歩行者
- ヘッドホンをつけている歩行者
- ヘッドホンをつけて歩きスマホを行う歩行者

通常の歩行者とは、スマートフォンやサングラス、ヘッドホンを使用していない歩行者のことである。なお、年齢や性別、服装など他の歩行者属性の影響を排除するために、本論文で着目しない歩行者属性については歩行者間で統一した。歩行者の気づきに関してより明確化するため歩行者に視線計測デバイスを装着させることも考えられるが、運転者に本実験の意図が分かっしまい、自然なデータを取れないと考え、採用しなかった。

まず、実験参加者に電動車いすの運転方法の説明を行った。上記の実験環境における練習走行を行い、その後実験を開始した。なお、実験中に、電動車いすに取り付けられたLiDARにより周囲の3次元点群を計測し、電動車いすの自己位置の推定[6]及び歩行者位置の取得を行った。また、歩行者属性は既知とした^(注1)。歩行者属性の組み合わせと歩行パターンを無作為に変えた試行を用意し、実験参加者1人あたり36試行の

(注1)：提案手法を実現するための電動車いすの要件としては、機械学習ベースの画像認識手法を用いて歩行者位置を取得（例えば[7]）するためのLiDARと歩行者属性を識別（例えば[8],[9]）するためのカメラを搭載していることである。

表1 提案手法と比較手法
Table 1 Compared and proposed methods.

Method	Pedestrian attribute	Driver skill	σ^2
Compared	×	×	σ_c^2
Proposed-1	○	×	$\sigma_p^2 \mathbf{s}_j$
Proposed-2	×	○	$\sigma_c^2 + k \cdot \text{skill}^i$
Proposed-3	○	○	$\sigma_p^2 \mathbf{s}_j + k \cdot \text{skill}^i$

データを取得した。

なお、本実験は名古屋大学未来社会創造機構の倫理審査委員会の承認を得て実施した。

3.2 評価実験

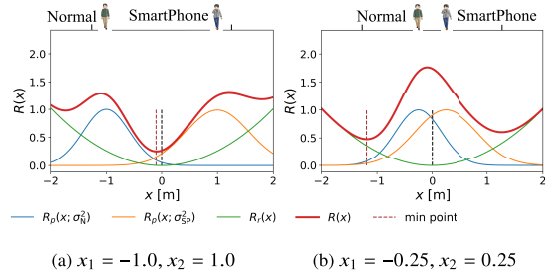
本実験では、2.1で設計し、2.2で推定したリスクポテンシャル関数を用いて、安全マージンの予測を行った。考慮するパラメータを変更して三つの提案手法と比較手法を用意した。表1に比較手法と提案手法の違いをまとめる。比較手法、提案手法1、2では、式(1)の σ^2 を変更して勾配降下法でパラメータを推定した。 σ_c^2 は比較手法、提案手法2において勾配降下法で推定されるパラメータの一つであり、提案手法1、3と異なり、歩行者属性を考慮しないため、歩行者属性によらず一定である。評価指標として、すれ違い時の電動車いすの位置の真値 x と予測値 \hat{x} の予測誤差を求める。それぞれの手法について5分割交差検証を行った。

結果として、比較手法のRMSEが0.947に対して、歩行者属性または運転スキルを考慮した提案手法1、2のRMSEがそれぞれ0.516、0.815となり、予測誤差の減少が確認された。更に、運転スキルと歩行者属性の両方を考慮した場合のRMSEが0.388と最も誤差が小さくなったことから、両方の要素が安全マージン予測の誤差低減に貢献していると考えられる。そのため、安全マージン予測のために運転スキルと歩行者属性を考慮することが必要であると考えられる。

最も誤差が小さかった提案手法3の最適パラメータは、5分割交差検証で推定したパラメータの平均 $\sigma_N^2 = 0.228$, $\sigma_{SP}^2 = 0.374$, $\sigma_{SG}^2 = 0.280$, $\sigma_{HP}^2 = 0.288$, $\sigma_{SP+HP}^2 = 0.369$, $a = 0.256$, $k = -0.112$ であった。歩きスマホのリスクポテンシャル関数の分散が大きく、通常の歩行者で分散が小さいという結果が得られた。そこで、属性によって以下のように危険度が異なると考えられる。

歩きスマホ+ヘッドホン \approx 歩きスマホ

> サングラス \approx ヘッドホン > 通常



(a) $x_1 = -1.0, x_2 = 1.0$ (b) $x_1 = -0.25, x_2 = 0.25$

図6 推定したリスクポテンシャル関数の例 (skill = 1.0)
Fig. 6 Example of the estimated risk potential function (skill = 1.0).

また、運転スキルに関するパラメータ k が負の値であったことから、運転スキルが高いほど安全マージンが小さくなっていると考えられる。逆に、運転スキルが低いほど安全マージンが大きくなっている。このように、歩行者属性によってリスクポテンシャル関数のパラメータが異なり、リスクが異なることから、歩行者に関して説明性が高いリスクポテンシャル関数は有用であると考えられる。

推定したリスクポテンシャル関数の例を図6に示す。図6(a)は、歩行者が $x = -1.0$ と $x = 1.0$ の位置にいた場合(道路の両端に分かれて歩行)のリスクポテンシャル関数を示す。また、図6(b)は、歩行者が $x = -0.25$ と $x = 0.25$ の位置にいた場合(道路の中央を並んで歩行)のリスクポテンシャル関数を示す。青色と橙色の線は、それぞれ通常の歩行者と歩きスマホの歩行者のリスクポテンシャル関数を示し、緑色の線は道路境界に関するリスクポテンシャル関数を示す。そして、赤色の線は三つの関数の和を示す。この赤色の線の値が最も低い場所でリスクが最小となるため、この場所を通過することが好ましいと考えられる。つまり、図6(a)では、 $x = -0.1$ 付近、図6(b)では、 $x = -1.3$ 付近を通過するのが好ましいと考えられる。

なお、本論文では、電動車いすと歩行者との速度差や進行方向は考慮していないが、それらもリスク及び安全マージンに影響すると考えられる。例えば、歩行者との速度差が大きい場合や進行方向が同じで追い抜く場合は、安全マージンが大きくなることが予想される。

4. むすび

本論文では、歩行者属性と運転スキルに着目して、歩行者との安全マージン予測手法を提案した。具体的には、それらを考慮したリスクポテンシャル関数を設

計し、運転データを利用してリスクポテンシャル関数のパラメータを最適化した。更に、実際にそれを用いて安全マージンを予測し、歩行者属性と運転スキルが安全マージン予測に貢献することを示した。歩行者属性については、「歩きスマホ」、「サングラス」、「ヘッドホン」に着目し、「歩きスマホ」の歩行者からは大きいマージンをとることを明らかにした。また、運転スキルが高い運転者ほど安全マージンが小さいことを明らかにした。

本論文で推定したリスクポテンシャル関数は図1のような2次元ポテンシャル場の計算に適用可能である。しかし、歩行者の進行方向や歩行速度など他の歩行者属性や状況に対しては Gaussian 関数が最適ではない可能性がある。そのため、より正確な安全マージンの予測のため、今後の課題として、それらを考慮する必要がある。

謝辞 本研究の一部は、科学研究費補助金 (JP19K12080, JP17H00745) による。

文 献

- [1] WHILL (ウィル), “MaaS | 次世代型電動車椅子 近距離モビリティ”. <https://whill.inc/jp/maas/>, 参照 Sept. 4, 2021.
- [2] WHILL, “MaaS | JISEDAIGATA DENDOKURUMAISU KINKYORI MOBILITY,” <https://whill.inc/jp/maas/>, Accessed Sept. 4, 2021.
- [3] P. Raksincharoensak, T. Hasegawa, and M. Nagai, “Motion planning and control of autonomous driving intelligence system based on risk potential optimization framework,” *Int. J. Automot. Eng.*, vol.7, no.AVEC14, pp.53–60, March 2016.
- [4] J. Wang, J. Wu, Y. Li, and K. Li, “The concept and modeling of driving safety field based on driver-vehicle-road interactions,” *Proc. 17th IEEE Int. Conf. Intelli. Transp. Syst.*, pp.974–981, Oct. 2014.
- [5] F. Shinmura, Y. Kawanishi, D. Deguchi, I. Ide, H. Murase, and H. Fujiyoshi, “Driver’s decision analysis in terms of pedestrian attributes — A case study in passing by a pedestrian,” *Proc. 20th IEEE Int. Conf. Intelli. Transp. Syst.*, pp.64–68, Oct. 2017.
- [6] Y. Huang, T. Mori, U.E. Manawadu, M. Kamezaki, T. Ishihara, M. Nakano, K. Koshiji, N. Higo, T. Tubaki, and S. Sugano, “Machine learning based skill-level classification for personal mobility devices using only operational characteristics,” *Proc. 2018 IEEE/RSJ Int. Conf. Intelli. Robots Syst.*, pp.5469–5476, Oct. 2018.
- [7] S. Thrun, D. Fox, W. Burgard, and F. Dellaert, “Monte Carlo localization for mobile robots,” *Proc. 1999 IEEE Int. Conf. Robot. Autom.*, pp.1322–1328, 1999.
- [8] Y. Zhou and O. Tuzel, “Voxelnet: End-to-end learning for point cloud based 3D object detection,” *Proc. 2018 IEEE Conf. Comput. Vis. Pattern Recognit.*, pp.4490–4499, June 2018.
- [9] F. Shinmura, Y. Kawanishi, D. Deguchi, I. Ide, H. Murase, and H. Fujiyoshi, “Recognition of texting-while-walking by joint features based on arm and head poses,” *Computer Vision — ACCV 2016 Workshops, Part I, Lecture Notes in Computer Science*, vol.10116, pp.452–462, March 2017.
- [10] T. Sikandar, W.W. Samsudin, K. Ghazali, I. Mohamed, and M. Rabbi, “Sunglass detection method for automation of video surveillance system,” *IOP Conf. Ser.: Mater. Sci. Eng.*, vol.342, no.012040, pp.1–9, April 2018.

(2021年6月1日受付, 9月5日再受付, 11月8日早期公開)