

論文・解説

18

走行環境の特徴を利用した危険予測技術

Risk Prediction Technology using the Context of the Driving Environment

菅野 崇^{*1} 黒田 康秀^{*2} 伏間 丈悟^{*3}
Takashi Sugano Yasuhide Kuroda Takesato Fushima山本 康典^{*4} 齊藤 裕一^{*5}
Yasunori Yamamoto Yuichi Saito

要約

本稿では、Mazda Co-Pilot Conceptの実現に向けた潜在的危険の予測技術として、他車の車線変更予測と歩行者、自転車の飛び出し予測について説明する。従来の車線変更予測では、予測対象とする他車の予備動作や周辺車両との車間距離から、車線変更を予測してきた。本研究では、予測対象が車線変更を決定する車間ギャップのモデルを応用することで、実際に車線変更を行う2.0秒前の予測が可能となり、他車の横方向からの衝突を回避可能とする目途が付いた。また、飛び出し予測では環境の危険度を予測する先行研究があるが、飛び出す対象が分かっている必要があった。そこで本研究では、飛び出すのが歩行者か自転車かを一方通行やビルの壁、歩道の有無などの環境特徴から予測する技術に取り組んだ。今回、統計的に説明できるようモデル化の検討を進めることで、環境特徴が歩行者、自転車の行動に影響を与えることが明らかになった。

Abstract

We have worked on developing the technology to predict potential risks, aiming for realizing Mazda Co-Pilot Concept. In this paper, we describe the prediction of lane changes and run-out of pedestrians or cyclists. In the prediction of lane change, we applied a model of the gap between vehicles where a prediction target decides to change lanes. By adjusting the parameters to the prediction target while driving, we achieved a prediction time faster than the target of 2.0 seconds. In the prediction of run-out, it is required to identify what the target is, according to the previous research to predict risks on environment. In order to make effective use of the research, we worked on a technique to predict whether the target of run-out is a pedestrian or a bicycle based on environmental features. By developing a model that can explain the prediction statistically with factual data, it became clear that environmental features influence the behavior of pedestrians and cyclists.

Key words : ADAS, Driving environment recognition, Co-Pilot

1. はじめに

Mazda Co-Pilot Conceptでは、万一、ドライバーが運転不能になった場合に、システムが車両をコントロールし、安全な場所へ停車する仕組みを提供することで、お客様に安全・安心なカーライフを提供する。Fig. 1にMazda Co-Pilot Conceptでの走行例を示す。心疾患などの要因による運転不能状態はいつでも発生しうることから、お客様がクルマを利用する高速道路から一般道での

作動が必要となる。

走行環境の危険は、Fig. 2に示すように顕在的危険と潜在的危険とに分類・整理できる⁽¹⁾。顕在的危険は衝突対象が明確であり、衝突被害軽減ブレーキや車間距離制御装置などの制御技術により除去されつつある。一方で潜在的危険は、衝突する対象が事前に見えない死角的危険と、隣接車線の他車など危険要因は見えるが衝突するか明確でない間接的危険があり、その対処はドライバーに任せられているのが現状である。これまで取り組んで

*1,3,4 統合制御システム開発本部
Integrated Control System Devel. Div.

*2 技術研究所
Technical Research Center

*5 筑波大学
University of Tsukuba

きた、間接的危険と死角的危険を予測する技術について報告する。




Fig. 1 Driving Example of Co-Pilot Concept (Local Roads)

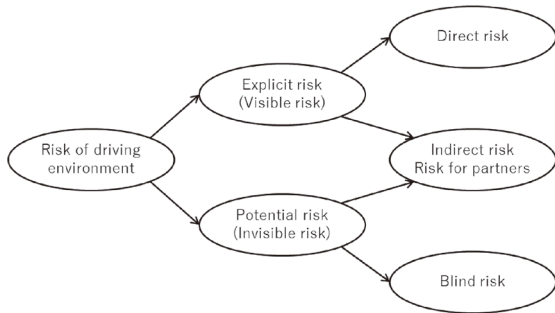


Fig. 2 Risks of Driving Environment

2. 取り組みの考え方

潜在的危険は不連続な走行環境の変化として現れる。そのため、その予測は運動方程式などの確定論的な手法ではなく、確率論的な手法を活用することになる。ビッグデータを利用しデータ駆動でモデル化していく技術が進歩してきているが、説明可能な状態でアルゴリズムの適用範囲を拡張していくため、全てをデータ駆動で構築するのではなく、人の行動を考えてモデル化し、その中に確率論的な振る舞いを織り込むことで性能を向上させた。

本稿では、これまでの検討事例として「他車の車線変更予測（間接的危険）」「飛び出し予測（死角的危険）」を説明する。

3. 他車の車線変更予測（間接的危険）

3.1 車線変更予測の課題

ドライバーが車を運転する際、周辺他車の行動を予測し、自車の行動を決定する。それをシステムが自動的に行う場合、前後方向については、レーダー等を用いて先行車との車間距離や相対車速をセンシングし、安全マージンを確保する行動決定が可能であり、車間距離制御装置（ACC）や衝突被害軽減ブレーキ（AEB）が商品化されている。一方、ジャンクションでの合流など他車の横方向の動きが生じる場面においては、あらかじめ車間距離を開けることや車線変更といった行動決定が必要となるが、車線間の他車の動きで対処しなければならず安全マージンが小さいのが問題である。

米国連邦運輸省の機関の1つである連邦道路管理局（Federal Highway Administration）が公開しているカメラから測定された交通データ⁽²⁾を用いて車両の動きを分析すると、平均的に車線を跨ぐ1秒程度手前まで、明確な横運動は発生しない。よって、目標達成には、車線変更の動きが出る前に関係する環境特徴を抽出し、予測に活用して精度を上げることが課題となる。

3.2 課題解決のアプローチ

車線変更の判断を事前に予測手法として人の行動メカニズムに則した Endsley の状況認知モデル⁽³⁾を参考に Fig. 3 に示す Step で開発を進めた。

Step 1：他車の車線変更そのものの動きではなく、それに備える予備動作の特徴量化（図中①）

Step 2：予測対象の状況認知をモデル化。他車を取り巻く相対位置や速度などの環境から予測（図中②）

Step 3：予測対象の内面・個人属性を判断予測に反映。横運動以外の行動から特性を予測（図中③）

Step 1 と Step 2 は予測対象の車線変更の際の振る舞いや周辺車両との相対運動を利用して予測する技術として報告している⁽⁴⁾⁽⁵⁾。本報告では Step 3 について説明する。

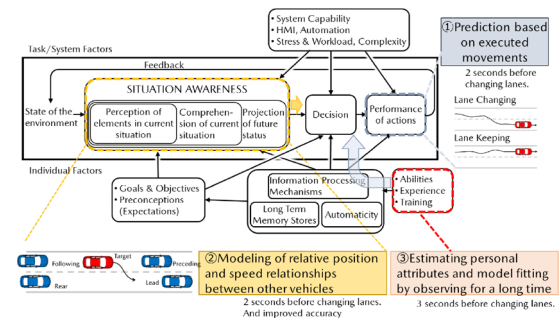


Fig. 3 Development Procedure of Lane Change Prediction

3.3 車線変更の行動分析と運転様式判別機能の構築

隣接車線の他車と他車との間に割り込む判断は、個人により異なる。この個人差を予測モデルに織り込むため Toledo らの先行研究⁽⁶⁾である Gap Acceptance Decision model (GAD) (Fig. 4) を参考とした。このモデルでは、予測対象が割り込み可能と判断する車間距離（Critical Gap）をパラメーターとしてもつ。この Critical Gap を個々の危険許容度に合わせることで、精度及び先読み時間の向上が期待できる。

ここで Critical Gap をどう事前に設定するかが問題となる。この問題についてドライバーの操作特性には運転行動全般で共通な因子があると考え、車線変更前の加減速行動や車間距離により層別できると仮説を立てて車線変更予測に運転様式判別機能（Driving Style Estimation: DSE）を追加した。

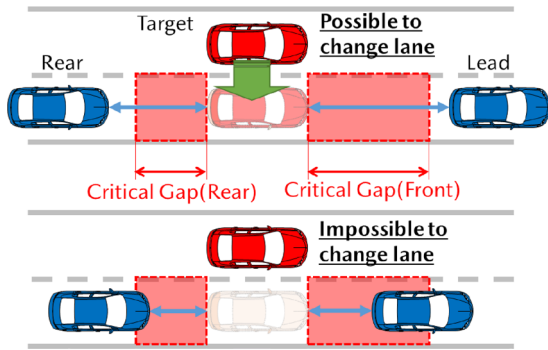


Fig. 4 Gap Acceptance Decision Model

(1) 車線変更予測の構成

車線変更予測の構成を Fig. 5 に示す。図の左側が Step 2 までで取り組んできたものであり、予測対象の横方向の予備動作や周辺他車との位置関係を利用するアルゴリズムである。右側が運転様式判別機能であり、予測対象の「穏やか」「積極的」などの特性を予測して Critical Gap のパラメータを修正し、GAD にて車線変更可否を判断する。車線変更予測全体としては、左右の処理を組み合わせ、確率的に車線変更の判断を推定する。

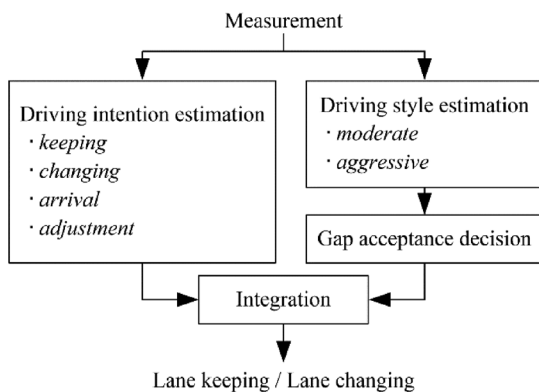


Fig. 5 Constitution of Prediction Model

(2) 運転様式判別機能 (DSE) の開発

ドライバーの運転様式の分類に追従走行における加減速行動の有効性を検討するため、ドライビングシミュレータ (DS) を用いて Fig. 6 に示すシーンを設定し被験者実験を行った。被験者が操作する車両を Target, 先行車を Preceding, 隣車線における先行車を Lead と定義した。これ以降、各車両を頭文字 (T, P, L) で表記する。




Fig. 6 Scenario of Subject Experiment

P と L には、車速 50km/h を基準としてランダムに ± 5km/h で変動させ、被験者は前方をふさがれた状態

での追従走行を行い、追い抜けるようなら追い抜くという指示 (タスク) が与えられた。また全ての被験者には、自身の意識を「慎重 (careful)」, 「積極的 (aggressive)」のいずれかで運転して頂くこととした。

なお、本研究で行った全ての被験者実験は、試験開始前にインフォームドコンセントを得て行っている。

運転様式判別にあたり、追従走行では先行車との距離や相対速度に応じて衝突危険を感じつつ、それを許容できる距離を確保しているという考え方から斥力ポテンシャルモデルを考慮した Driving Risk Factor (DRF) を用いた。これまで障害物に対する距離の自然対数を使ったモデル⁽⁴⁾が提案されているが、本研究では速度変動を反映できるよう改良し式(1)とした。

$$U_i = \frac{\exp[\varepsilon(\Delta v_i)\cos\theta_i]}{2\pi l_0[\varepsilon(\Delta v_i)]} \alpha \frac{\exp\left[-\frac{r_i^2}{2\sigma_i^2}\right]}{2\pi\sigma_i^2} \quad (1)$$

ここで、 r_i は推定対象車との車間距離 (m), σ_i は車間距離の分散量 (m^2), Δv_i は推定対象車との相対速度 (m/s), θ_i は相対角度 (rad), α は係数である。また ε は Δv_i により定まるパラメータであり、ポテンシャルが高まる方向を決定する機能をもつ。添え字 i は、車両を示す番号であり、Fig. 6 の場合は P と L の 2 台なので、1 もしくは 2 となる。

被験者実験の結果例を Fig. 7 に示す。図中 D_x は車間距離、 V_{rx} は相対速度、 U は DRF を表し、それぞれの平均的な値で正規化した値で示す。慎重な走行と積極的な走行とを比較すると、3 つの特徴量のそれぞれで違いがあるが、DRF の変動には、大きな違いが生じることが見て取れるため、DSE では分類器として Support Vector Machine (SVM) を使い、ドライバーの運転様式を判別するようにした。この際の入力候補として、車間距離 (Distance), 相対速度 (Rel. velocity) に加え、①車間距離変動をゲイン、減衰比で特徴化したもの②1/TTC, ③KdB (接近離間状態評価指標) と④提案手法である DRF を比較した結果を Table 1 に示す。提案手法は 69.0% の推定精度であり他のものよりも良い性能であることが確認できる。

Table 1 Comparison of Behavior Estimation Models

Feature vector	Estimation accuracy (%)
① (gain parameter, damping ratio)	41.5
② (Distance, Rel. velocity, 1/TTC)	63.8
③ (Distance, Rel. velocity, KdB)	65.1
④ (Distance, Rel. velocity, DRF)	69.0

3.4 車線変更予測の性能評価

前述のとおり、提案手法は T の走行から運転様式を予測し、GAD の Critical Gap に反映させる。DSE は「慎重」と「積極的」の境界面からの距離 u に基づいて、そのク




Fig. 7 Example of Driving Result (upper: careful, lower: aggressive)

ラスに属する確率の連続値として出力する。Critical Gap の前方側を G_f 、後方側を G_r として、下記の式に基づき設定した。

$$G_f = \exp(\gamma_f + \alpha_f \Delta V_f(t) \operatorname{sgn}(\Delta V_f(t)) + \beta_f v(t)) \quad (2)$$

$$G_r = \exp(\gamma_r + \alpha_r \max(0, \Delta V_r(t)) + \beta_r v(t)) \quad (3)$$

ここで、 $\alpha_f, \beta_f, \gamma_f, \alpha_r, \beta_r, \gamma_r$ は係数である。また $\Delta V_f, \Delta V_r$ は Fig. 4 での時刻 t における Target と Lead 及び Rear との相対速度を表し、 $\operatorname{sgn}(\cdot)$ は符号関数である。

評価にあたり使用したデータ⁽²⁾ は San Francisco Bay 地域における I-80 番道路のもので、289 台の車線変更データを用いて推定モデルの学習を行い、285 台のデータにより性能評価を行った。評価指標として予測精度は Table 2 の F_1 値を用いる。予測先出時間 τ_d は、車線変更すると推定された時刻 τ_j 、ターゲット車が中央線を越える時刻を τ_c から次式とした。

$$\tau_d = \tau_c - \tau_j \quad (4)$$

予測先出時間が大きい値をもつほど優れた早期認識性能をもつことを表し、単位は秒となる。上記の指標を用いて車線変更推定の成敗基準を以下に設定した。

- Success: 一定時間内に推定された場合 ($0 < \tau_d < 5.0$)
- Failure: 推定時刻が車線変更時刻より遅い ($\tau_d \leq 0$)
- False alarm: 推定時刻が早すぎる場合 ($\tau_d \geq 5.0$)

結果を Table 2 に示す。Step 1+2+3 の予測先出時間は、車線変更による衝突を通常域の減速 (0.24G 程度)

で回避できることを意味する。

Table 2 Comparison of Intention Estimation Models

	Step1+2	Step1+2+3
Predictive Accuracy (F_1 score)	97.1%	97.1%
Foresight time	1.92s	2.07s

4. 飛び出し予測 (死角的危険)

4.1 飛び出し予測の課題

飛び出す対象は「歩行者」、「自転車」、「オートバイ」、「自動車」、「その他」があるが、法律による制約が少なく、自由に移動する「歩行者」と「自転車」はルールベースでの予測が難しいと考えられ、これらを対象とした予測技術に取り組む。

先行研究では、衝突回避のため急減速までの余裕時間 (Safety Cushion Time: SCT) を指標にした研究⁽⁷⁾⁽⁸⁾ があるが、飛び出す対象を「歩行者」か「自転車」のどちらかに固定した条件で SCT を予測している。しかし、実際には事前に飛び出す対象は分からないことが問題である。

一般的に Fig. 8 に示すような道路環境の因子のなかには、路面の段差や縁石、道路の幅、優先・非優先など自転車の行動に影響を与えるが、歩行者にはあまり影響しないものがある。そこで、「飛び出し事象が生じるときは、道路環境の因子から説明することが可能である。」という仮説を立案した。この作業仮説を検証し、飛び出す対象に影響を与える因子を明確にすることが課題である。



Fig. 8 Context Example (priority/non-priority, road width, etc.)

4.2 課題解決のアプローチ

東京農工大学スマートモビリティ研究拠点が運営しているヒヤリハットデータベース (HHDB) を用いて、対歩行者また対自転車のニアミス事象を抽出し、そのデータに対して、道路環境の因子にアノテーションを付す。この因子と飛び出してきた対象と結びつける回帰モデルを用いて仮説検証する。

4.3 飛び出し対象のデータ分析による環境因子の抽出

データ抽出に際して、例えば、バスなどの駐車車両の陰から飛び出してくるのは歩行者であることが多い。そこで、死角を作っている要因について分類を行うと Table 3 のようになった。結果から歩行者は建物の影から飛び出すケースがやや多いが、自転車は建物の影が圧倒的に多いことがわかる。このように明らかな傾向がみられることから、これらの因子を採用し先行研究⁽⁷⁾⁽⁸⁾に用いられている特徴量に死角要因を加え、扱う環境因子を Table 4 とした。

Table 3 Number of Data Related to Blind Spot

Blind factor	Pedestrian	Cyclist
Building wall	267	459
Parked vehicle	150	63
Stopped vehicle	190	105
Moving vehicle	138	54
Total	745	681

Table 4 Context Property Based on Annotations

Type	Definition
Lateral gap	Lateral distance to blind object (m)
Area	Residential, Urban & Business, Rural, Other
Road	One way, Both way, Other
Side	None, Line, Step, Guardrail
Intersection	2~3 forked road, 4~5 forked road, 6~ forked road, Straight
Width	1~3 lanes, 4~ lanes, Other
Crosswalk	Without, With
Parked vehicle density	0, Low (1~2), Middle (3~5), High (6~)
Pedestrian density	Low (0~2), Middle (3~9), High (10~)
Traffic density	Low (0~2), Middle (3~9), High (10~)
Leading vehicle	Without, With
Parked vehicle type	Passenger vehicle, Track, Bus
Time	6:00~10:00, 10:00~16:00, 16:00~20:00, 20:00~6:00
Weather	Sunny, Rain
Blind spot	Building wall, Parked vehicle, Stopped vehicle, Moving vehicle
Age	Unknown, Elderly, Mature, Young, Child

4.4 判別式の構築と性能評価

(1) 判別式と評価方法

ここで行う判別は特定事象の発生率の予測であるため、ロジスティック回帰分析を用いた。目的変数は、飛び出し対象 (1: 自転車, 0: 歩行者) であり、説明変数は主に道路環境の因子である。判別式を式(5)に示す。

$$y = \frac{1}{1 + \exp[-(\alpha_1 x_{11} + \alpha_2 x_{12} + \dots + \alpha_i x_{ji} + b_j)]} \quad (5)$$

ただし、 x_{ji} は因子であり、Table 4 の該当因子ごとに、1 or 0 を設定するものである。ただし、横位置のみは定量値として設定する。

評価はステップワイズ法を用いて、説明変数を選択した上でオッズ比 (OR) を用いて行った。オッズとは p を確率とすると、 $p/p-1$ として表される。分割表の例を Table 5 に示す。

Table 5 Example of Contingency Table (crosswalk)

	Cyclist	Pedestrian	Total
With crosswalk	A	B	A+B
Without crosswalk	C	D	C+D
Total	A+C	B+C	A+B+C+D

因子の中に横断歩道があった場合、 p を自転車が飛び出してくる割合とおくと、 $1-p$ は歩行者の割合を意味する。このことから、 $p=A/(A+B)$ 、 $1-p=B/(A+B)$ である。横断歩道ありの因子におけるオッズは下記で示される。

$$\frac{p}{1-p} = \frac{A/(A+B)}{B/(A+B)} = \frac{A}{B}$$

同様に、横断歩道なしの因子におけるオッズは下記となる。

$$\frac{p}{1-p} = \frac{C/(C+D)}{D/(C+D)} = \frac{C}{D}$$

オッズ比はこれらの比を表現することから式 (6) となる。

$$OR = \frac{A/B}{C/D} = \frac{AD}{BC} \quad (6)$$

オッズ比=1 の場合、その因子は目的変数に影響を与えないことを意味する。また、オッズ比>1 の場合は目的変数に対して正の影響、オッズ比<1 の場合は目的変数に対して負の影響があることになる。

(2) 性能評価

HHDB から、歩行者と自転車それぞれ 550 件のデータを用いてモデルを学習させ、195 件の歩行者、131 件の自転車データを用いて評価した。回帰分析の結果を Table

6に示す。オッズ比は確率の比であることから95%信頼区間が存在し、Table 6ではその上下限を示す。この区間に1を含まなければ、その因子は有意であると見なせ、その因子のみを残した。因子「都市&ビジネス」「一方通行」「交通密度 低」「交通密度 中」は、目的変数に負の影響を与えることから歩行者であると判断する方向へ作用し、それ以外は、自転車である方向へ作用することが統計的に説明できる。

Table 6 Logistic Regression Analysis

Factor	Lower OR	Upper OR
Urban & Business	0.50	0.98
One way	0.36	0.88
Sidewalk: Step	1.18	2.21
1~3 lanes	1.23	2.27
Traffic density: Low	0.22	0.87
Traffic density: Middle	0.21	0.78
Without leading vehicle	1.08	2.24
Time: 10:00-16:00	1.07	2.34
Time: 16:00-20:00	1.51	3.47
Parked vehicle type:		
Passenger vehicle	1.01	3.31
Building wall	1.51	3.52
Stopped vehicle	1.06	2.88
Lateral gap	1.19	1.53

分析結果について解釈すると、都市部は歩行者の数が多い場所であり一方通行が多く車両が少ないことから、より自由に行動する場所であることなど印象と一致している。自転車と識別する要因については、建物・壁が死角の要因になるときに、飛び出すのが自転車である確率はTable 3より63%となり歩行者よりも確率が高くなるが、オッズ比も同方向へ作用している。また時間帯については、自転車は業務でも使うことから、日中〜夕方にかけて飛び出しが増えるのであろう。対面で走行してくる自転車について、避けやすい乗用車の場合は減速せず飛び出すが、大型車では横移動が大きく慎重になると考えられ、主観と一致する。

この特徴量を使った飛び出し対象の予測性能をTable 7に示す。この結果から正解率は76%となる。この性能は、飛び出し発生時の急減速の頻度を12%改善することに相当する。以上の結果から、道路環境の因子から説明することが可能であることが検証され、飛び出し対象に影響を与える因子を明確にすることができた。

Table 7 Prediction Results from Classification Model

	Prediction		
	Pedestrian	Cyclist	
Actual	Pedestrian	147	48
	Cyclist	29	102

5. おわりに

他車の車線変更予測と飛び出し予測について取り組んだ。車線変更予測では、車線内走行における加減速、車間距離の行動モデルを構築し、そのモデルを用いて他車の運転様式を判別することで予測性能を向上させた。飛び出し予測では、環境特徴から飛び出してくるのが歩行者か自転車かを判別する機能を開発し、予測性能の向上の目的が立った。

いずれの取り組みも、予測器の構成を意味のある機能に分解し、必要に応じて統計的な手法でモデル化することで、どのような機能・性能を有しているかを分かりやすく示すことができる。今後も機能・性能の向上を計画的に進めていく。

参考文献

- (1) 蓮花一己：交通危険学，啓正社
- (2) M. R. Endsley: Measurement of Situation Awareness in Dynamic Systems, Human Factors, Vol.37, No.1, pp.65-84 (1995)
- (3) The Federal Highway Administration: Next Generation Simulation, <http://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm> (accessed: 10 May 2015)
- (4) Hanwool Woo et al.: Dynamic Potential-Model-Based Feature for Lane Change Prediction, 2016 IEEE International Conference on Systems, Man, and Cybernetics (SMC), (2016)
- (5) Hanwool Woo et al.: Lane Change Detection in Other Vehicles Based on Vehicle Trajectory Prediction, IEEE Robotics and Automation Letters, Vol.2, No.2, pp.1109-1116 (2017)
- (6) T. Toledo et al.: Modeling duration of lane changes, Transportation Research Record, Journal of the Transportation Research Board, Vol.1999, pp.71-78 (2007)
- (7) ポンサトーン・ラクシンチャラーンサク：リスクポテンシャル予測による自動車の障害物回避運動制御，計測と制御，Vol.54, No.11, pp.820-823 (2015)
- (8) 齊藤裕一，井上秀雄，ポンサトーン・ラクシンチャラーンサク，セイフティクッション：走行環境文脈と運転行動状態に基づく危険度推定モデルの構築（第一報）—死角での対歩行者ヒヤリハットの形成過程に対する考察—，2018年度自動車技術会春季大会学術講演会予稿集，文献番号 20185429 (2018)

■著者■



菅野 崇



黒田 康秀



伏間 丈悟



山本 康典



齊藤 裕一