

状態単位の隠れマルコフモデルを用いた 他車の車線変更推定手法

禹ハンウル*, 池勇勳*, 河野仁*, 田村雄介*, 山下淳*, 浅間一*

Estimation Method for Lane Changes of Other Traffic Participants Using State-Unit based Hidden Markov Models

Hanwool WOO*, Yonghoon JI*, Hitoshi KONO*, Yusuke TAMURA*,
Atsushi YAMASHITA* and Hajime ASAMA*

* Department of Precision Engineering, The University of Tokyo
7-3-1 Hongo, Bunkyo-ku, Tokyo, 113-8656 Japan

Previous researches reported that a lane change is the main cause of vehicle accidents. Therefore, inferring behaviors in other drivers and alarming to a driver are crucial tasks for safety. In this paper we propose a method to estimate lane changes of other drivers using state-unit based Hidden Markov Models (HMM). Comparing the proposed method with previous researches, we confirmed this method has higher and earlier performances to detect a lane change in other vehicles.

Key Words : Lane change detection, State-unit based HMM, External measurements

1. 序 論

近年、自動運転車が注目を浴びており、実用化に向けて研究が盛んに行われている。アメリカの国防高等研究計画局は2007年に自動走行技術の研究を加速させるためのDARPA Urban Challengeという大会を開催した。日本では、2014年に自動走行システム研究開発計画が発表され、内閣府は2020年までに世界で最も安全な道路交通社会を実現すると公表した⁽¹⁾。自動走行技術を用いることにより、交通渋滞の緩和、高齢者の移動支援、運転の快適性向上が期待されるが、中でも交通事故の低減が最も期待されている。

交通事故は車が車線変更を行う際に最も多く発生しており、他車の危険な車線変更による衝突が数多く生じている。先行調査では、約40%の運転者のみが車線変更を行う際に方向指示器を使用すると報告されている⁽²⁾。そのため、方向指示器以外の情報を用いた車線変更推定手法が多く提案されている。車線変更推定は、自車の運転者の意図推定と周辺を走る他車の意図推定の2つに分類することができる。Kugeらは隠れマルコフモデル (Hidden Markov Model, HMM) を用いた車線変更推定手法を提案し、車線からの距離、ステアリング角度を特徴量として用いた⁽³⁾。Kugeらは日本の高速道路で測定されたデータによる提案手法の評価

を行い、約98%の精度で自車の車線変更推定を可能とした。Liらは自車のCAN-bus情報のみを用いた推定システムを提案し、SFFS (Sequential Forward Floating Selection) による有効特徴量選別を行った⁽⁴⁾。その結果、ステアリング角度、車線垂直方向における速度と加速度、ブレーキペダル踏み角度、ヨー角速度が最も有効な特徴量であると報告した。さらに、運転者の視線情報、ハンドル角度などの情報を用いることにより推定精度の向上を試みた研究も存在する^{(5),(6)}。しかし、交通事故予防の観点からすると、自車より他車の車線変更を推定し、より早く衝突回避行動を取ることが重要である。KugeらとLiらが用いた特徴量は外部から測定することができないため、上記の手法を他車の車線変更に適用することは不可能である。

Schlechtriemenらは他車の車線変更推定を想定し、外部から測定することが可能な情報のみを用いた推定手法を提案した⁽⁷⁾。Schlechtriemenらは自車の周辺を走る他車の車線垂直方向における速度と位置、先行車との相対速度を特徴量とした。また、Dingらは走行車線と隣車線を走る車群の平均速度差、自車と先行車との衝突予想時間、隣車線の後続車との車間距離を特徴量に含め、より早く車線変更を推定することを試みた⁽⁸⁾。しかし、この手法は先行車が自車より遅く走行していることを仮定しており、他の車線変更推定には不適切である。例えば、前方に大型車両があるため、車

* 東京大学大学院工学系研究科精密工学専攻 (113-8656 東京都文京区本郷 7-3-1) {woo, ji, kono, tamura, yamashita, asama}@robot.t.u-tokyo.ac.jp




Fig. 1 問題定義

線変更を行う場合が考えられる。また、合流時点においては必ず車線変更を行う必要があり、先行車との相対速度は重要な要因ではないと言える。以上の状況以外にも様々な理由により車線変更が行われるが、従来手法では適切な推定が行われない可能性がある。

本研究では、図 1 (a) に示すような合流点と分岐点を有する道路におけるすべての車線変更について推定を行う。また、図 1 (b) に示すような隣車線を走る車が自車の前方へ車線変更を行う場合を想定し、外部から測定可能な情報のみを用いた他車の車線変更推定手法を提案する。測定装置としてはレーザースキャナーやカメラを想定し、他車の中央線からの位置を計測する。計測した位置情報とその時間変化分である車線垂直方向速度のみを特徴量として用い、他車における車線変更推定を可能とする。手法の推定精度においては、車線変更認識精度に加え、車線維持する場合を車線変更すると判断する誤認識率までを考慮する。従来手法は、先行車との相対量の特徴量に含めることで、より早く車線変更を認識しているが、これにより誤認識率が高くなってしまいう問題が生じる。本研究では、先行車との相対量の特徴量から排除することにより誤認識率を改善する。しかし、これにより推定時間が従来手法より遅くなってしまいう恐れがある。そこで本研究では、状態を認識単位とする HMM による車線変更認識を行うことで、推定時間性能の劣化を防ぐ。HMM による車線変更推定は、一般的に車線変更と車線維持の HMM をそれぞれ構築し、2つのモデルにおける尤度を比較することにより行われる。これはモデルを認識単位とする構造である。これに対し、運転者の意図を

HMM の状態として定義し、運転者の意図が車線維持することから車線変更することに移る状態遷移を推定する構造が考えられる。これは状態を認識単位とする構造である。後述の構造は、認識単位が時間的に短いため、前述のモデルを認識単位とする手法に比べ、早く車線変更を推定することが期待できる。本研究では、運転者の意図を HMM の状態として定義し、この状態を認識単位とする HMM 構造を用いる。

2. 車線変更推定手法

2.1 HMM 設計 本研究では、外部から測定可能な情報のみを用い、HMM による他車の車線変更推定を行う。HMM は直接観察することができない内部状態を観測可能な情報を計測することにより推定することができるモデルであり、運転者によってばらつきが予想される不確実性を持つ問題を確率的に捉え、統計的な処理によるモデル化を行うことで、有効に対処できる手法である。本研究では、車線変更が図 2 (a) に示すような「維持、変更、調節」の3段階で行われると仮定し、各段階を HMM の状態として定義する。各状態の定義を以下に示す。

- ・維持 (Keeping) : 現在の走行車線を維持する状態
- ・変更 (Changing) : 隣車線に移動する状態
- ・調節 (Adjustment) : 車線変更を終え、車群の速度に合わせる状態

計測される特徴量から現時点における HMM の状態を推定する。本研究では、推定された状態が「維持」から「変更」へ遷移すると、他車は車線変更を行うと

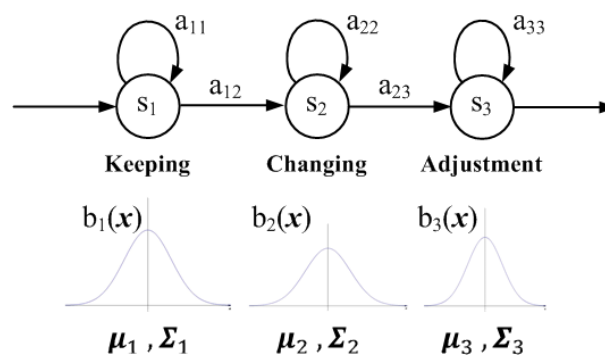



Fig. 2 本研究における HMM 構造




Fig. 3 特徴量ベクトルの定義

判断する。車線変更を行わない車は「維持」状態が続くこととなる。本研究における状態推定は、図2(b)に示す構造を用いた連続分布型HMMにより行われる。車線変更推定においてはleft-to-right構造が有効であると先行研究により報告されている⁽³⁾。本研究では、left-to-right構造を用い、各状態における特徴量の出力確率はガウス分布に従うとする。

HMMに用いる特徴量は推定精度を左右する最も重要な要素であり、測定可能なすべての特徴量を用いるより、有効な特徴量のみを用いた方が優れた推定性能を得られると報告されている⁽⁷⁾。本研究では、他車の車線変更推定を想定しているため、外部から測定可能な特徴量のみを用いる必要がある。また、車線維持する場合を車線変更すると判断する誤認識率を抑えるため、先行車との相対速度や隣車線を走る車群との速度差などは特徴量に含めない。図3に提案手法が用いる特徴量を示す。本研究では、中央線からの位置 x_{cl} と車線垂直方向の速度 v_x を特徴量とする2次元の特徴量ベクトル \mathbf{x} を定義する。

自車に実装される計測装置により測定される特徴量には誤差が含まれることが予想されるため、現在までのある時間幅内に測定されたデータ間の平均化によるフィルタリングを行う。また、各次元における特徴量の大きさによる影響を抑えるため、正規化を行う。しかし、提案手法を車に実装し、オンラインで推定を行う際には全データから平均と標準偏差を求めて正規化を行うことは不可能であるため、平均と標準偏差による正規化は本手法に適さない。本研究では、各次元における特徴量の最大値による正規化を行う。中央線からの位置 x_{cl} は車線の幅を最大値とし、車線垂直方向速度 v_x は全学習データの中から最も大きい値を最大値とする。

2.2 学習によるHMM構築 定義されたHMMは実際の交通データを用いたEMアルゴリズムによる学習を行う⁽⁹⁾。学習によりHMMは状態遷移確率 a_{ij} 、特徴量ベクトルの期待値ベクトル μ_i 、共分散行列 Σ_i が更新される。状態遷移確率 a_{ij} は状態 i から状態 j へ遷移が生じる確率を表し、期待値ベクトル μ_i と共分散行列 Σ_i は状態 i における特徴量ベクトル \mathbf{x} の特性である。

$$a_{ij} = P(q_{t+1} = j | q_t = i) \quad (1)$$

ここで q_t は時刻 t における状態を表す。時刻 T までの特徴量ベクトル系列を $\mathbf{x}_1^T = \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T$ とし、モデル M が時刻 t で状態 i に到達する確率 $\alpha_t(i)$ を導入する。

$$\alpha_t(i) = P(\mathbf{x}_1^t, q_t = i | M) \quad (2)$$

この $\alpha_t(i)$ は次式で求められ、前向き確率と呼ぶ。

$$\alpha_t(i) = [\sum_{j=1}^N \alpha_{t-1}(j) a_{ji}] b_i(\mathbf{x}_t) \quad (3)$$

ここで $b_i(\mathbf{x})$ は状態 i における特徴量ベクトル \mathbf{x} が得られる確率である。

$$b_i(\mathbf{x}) = \frac{1}{(2\pi)^{k/2} |\Sigma_i|} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mu_i)^T \Sigma_i^{-1} (\mathbf{x} - \mu_i)\right\} \quad (4)$$

次に前向き確率 $\alpha_t(i)$ と相対な後ろ向き確率 $\beta_t(i)$ を導入する。

$$\beta_t(i) = P(\mathbf{x}_{t+1}^T | q_t = i, M) \quad (5)$$

後ろ向き確率 $\beta_t(i)$ は状態 i から始まる状態遷移により \mathbf{x}_{t+1}^T が生成される確率であり、次式で求まる。

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(j) \quad (6)$$

以上の前向き確率 $\alpha_t(i)$ と後ろ向き確率 $\beta_t(i)$ を用い、学習によるHMMの再推定を以下のように行う。

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \alpha_t(i) a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^{T-1} \alpha_t(i) \beta_t(i)} \quad (7)$$

$$\bar{\mu}_i = \frac{\sum_{t=1}^T \alpha_t(i) \beta_t(i) \mathbf{x}_t}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (8)$$

$$\bar{\Sigma}_i = \frac{\sum_{t=1}^T \alpha_t(i) \beta_t(i) (\mathbf{x}_t - \bar{\mu}_i)(\mathbf{x}_t - \bar{\mu}_i)^T}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (9)$$

式(2)から式(9)までの計算を繰り返すことにより、尤度 $\sum_{i=1}^N \alpha_T(i)$ が最大となるようHMMの構築を行う。反復計算は尤度が収束するまで行う。

2.3 他運転者の内部状態推定 学習により構築されたHMMを用い、他車の特徴量ベクトル系列 \mathbf{x}_1^T から現時刻 $t = T$ における他運転者の内部状態 q_T を推定する。特徴量ベクトル系列 \mathbf{x}_1^T は、時刻 $t = 1$ から現時刻 $t = T$ までの特徴量ベクトル \mathbf{x} の集合である。この特徴量ベクトル系列 \mathbf{x}_1^T から $P(\mathbf{x}_1^T, q_1^T | M)$ を最大化する最尤状態遷移系列 q_1^T の推定を行い、最後の状態 q_T を現在の状態とする。特徴量ベクトル系列 \mathbf{x}_1^T を生成し、時刻 t で状態 i に達する状態遷移系列 q_1^t は複数存在するが、全ての状態遷移に対して計算を行うのではなく、可能性の高い状態遷移のみを計算する方法

として Viterbi アルゴリズムが用いられる⁽¹⁰⁾。時刻 t に状態 i へ到達する最大の確率値を $\delta_t(i)$ と表す。

$$\delta_t(i) = \max_i P(q_t^{-1}, q_t = i, \mathbf{x}_t^1 | M) \quad (10)$$

$\delta_t(i)$ は以下の式から再帰的に求めることができる。

$$\delta_{t+1}(j) = \max_i [\delta_t(i) a_{ij}] b_j(\mathbf{x}_{t+1}) \quad (11)$$

現時刻 $t = T$ における最尤な状態 q_T は次となる。

$$q_T = \arg \max_i \delta_T(i) \quad (12)$$

以上より他車の特徴量から現時刻 T における他運転者の内部状態 q_T を推定することが可能である。

3. 提案手法の評価

3.1 学習および評価データ HMM の構築および提案手法の評価には、米国連邦運輸省の機関の一つである連邦道路管理局 (Federal Highway Administration) が公開している実際に測定された交通データを用いた⁽¹¹⁾。測定は California 州の Los Angeles に位置する US-101 道路で行われた。データは約 640 m の区間を 8 台のカメラを用い、15 分間の交通流を 3 回計測したものであり、0.1 秒刻みに記録されている。測定場所の概要を図 4 に示す。概念図における一番上の車線を 1 番車線とし、順に車線番号を与え、合流点と分岐点に繋がる車線を 6 番車線と定義した。

本研究では、測定場所を通る全車両の中で車線変更を行った車両を 3 つのケースに分類した。1 つ目は合流点から入り、6 番車線から 5 番車線に車線変更を行うケースである。合流点から入った車はそのまま走行すると分岐点へ出てしまうため、必ず車線変更を行う必要がある。このような必ず車線変更を行う必要がある場合を従来研究では義務的車線変更 (Mandatory Lane Change : MLC) と定義している⁽¹²⁾。本研究では、合流地点における義務的車線変更を「MLC1」とした。2 つ目は分岐点へ出るために 5 番車線から 6 番車線に車線変更するケースである。このケースも義務的車線変更の一つであり、本研究では「MLC2」と定義した。3 つ目は測定場所で行われた全車線変更の中、MLC1 と MLC2 以外のすべての車線変更を任意的車線




Fig. 4 測定場所の概要図

Table 1 車線変更データの分類

No.	時刻	変更数	分類	車両数	使用
1	7:50 - 8:05	601	DLC	385	学習
			MLC1	171	
			MLC2	45	
2	8:05 - 8:20	394	DLC	250	評価
			MLC1	102	
			MLC2	42	
3	8:20 - 8:35	400	DLC	257	評価
			MLC1	109	
			MLC2	34	

変更 (Discretionary Lane Change : DLC) であると扱い、「DLC」と定義した。測定場所における車線変更車両を分類した結果を表 1 に示す。本研究では、HMM 構築のために 15 分間測定された 3 つの交通データセット中、1 つを学習データとして用いた。また、提案手法の有効性を評価するため、2 つ目と 3 つ目の交通データセットを用いた。

分類の結果、DLC を行った車両数は全車線変更車両数の約 61 %であることを確認した。この結果から従来手法は測定場所における全車線変更車両の約 61 %以下しか車線変更を推定することができないと言える。

3.2 提案手法の推定精度評価 前節で分類を行った交通データを用い、DLC, MLC1, MLC2 それぞれにおける提案手法の推定精度評価を行った。各車両データにおける推定成敗の判定基準は、提案手法により推定された状態が「維持」から「変更」へ遷移する時刻とした。以降、この推定時刻を τ_{est} とする。推定時刻 τ_{est} が車線変更を行う車が中央線に接する時刻前であることを 1 つ目の成功判定条件とした。以降、車が中央線に接する時刻を τ_{rch} とする。また、推定時刻 τ_{est} と車が中央線に接する時刻 τ_{rch} との差を τ_{gap} と定義し、時間差 τ_{gap} が 5 秒以内であることを 2 つ目の成功判定条件とした。一般的に車線変更は 3 秒から 5 秒以内に行われると従来研究で報告されており、時間差 τ_{gap} が 5 秒を越える場合を False alarm であると判定した。以上の 2 つの成功判定基準により提案手法の推定精度評価を行った結果を表 2 に示す。

解析の結果、すべての評価データにおき、推定対象車が中央線に接する前に車線変更を推定することが可能であった。評価データ中の 1 台の車における推定結果を図 5 に示す。図 5 (a) は正規化された特徴量の履歴を表し、図 5 (b) は提案手法により推定された対象車の状態を表す。推定状態の値が 1 であるときに「維持」状態を表し、値が 2 であるときに「変更」状態を意味する。推定状態が 1 から 2 に変化する瞬間が提案

Table 2 提案手法の評価結果

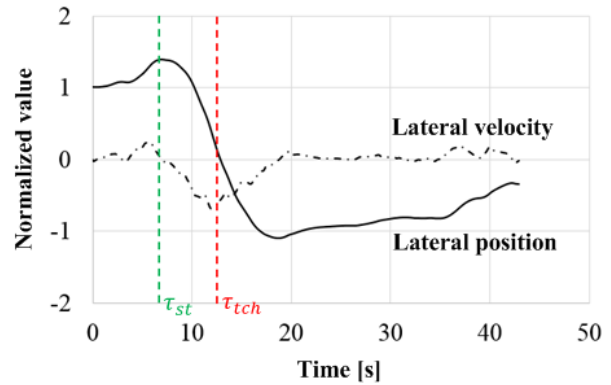
No.	時刻	分類	車両数	成功	失敗	False alarm	正確度 [%]	τ_{gap} [s]	正確度 [%]	τ_{gap} [s]
2	8:05 - 8:20	DLC	250	250	0	26	90.0	2.2	91.0	2.2
		MLC1	102	102	0	5	95.1	2.2		
		MLC2	42	42	0	13	69.0	2.1		
3	8:20 - 8:35	DLC	257	257	0	16	93.8	2.1	91.0	2.2
		MLC1	109	109	0	3	97.2	2.3		
		MLC2	34	34	0	11	67.6	1.9		

手法により対象車が車線変更を行うと判断された時刻 τ_{est} である。図 5 (b) から推定時刻 τ_{est} が車線変更を始める時刻 τ_{st} と車両が中央線に接する時刻 τ_{ch} の間となることが確認できる。この結果から、他車が中央線に接する前に提案手法が車線変更を正しく推定できることが示された。

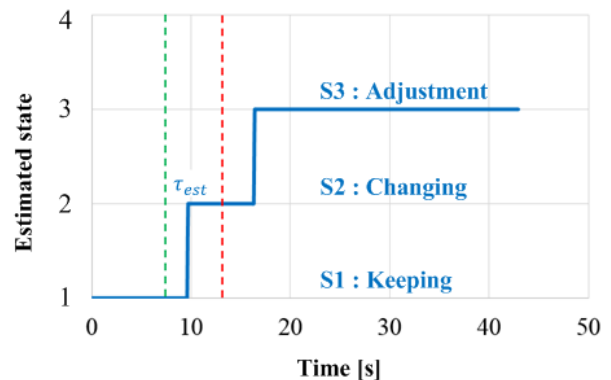
しかし、多くの False alarm が発生する問題が確認された。False alarm に対する提案手法の性能を評価する指標として正確度 (Precision) を用いた。正確度は車線変更すると正しく推定されたデータ数に対する車線変更すると推定された総データ数で算出される。解析の結果、DLC と MLC1 における正確度は 90 % を上回る値が得られた。しかし、MLC2 における正確度は約 68 % となり、推定性能が落ちることが確認された。図 6 に MLC2 における False alarm が発生する様子を示す。図 6 から車線変更を開始する前にも車の位置が揺らいでいることが分かる。解析の結果、DLC と MLC1 に比べ、MLC2 を行う前に車両の揺らぎが大きいことが確認された。運転者は車線変更を試みたものの、隣車線の先行車や後続車により車線変更を中止することが要因の一つであると考えられる。今後、隣車線を走行する先行車と後続車との関係性を考慮することによる False alarm の低減を目指す。

3.3 提案手法の推定時間評価 提案手法の有効性を評価する際、他車が中央線に接する何秒前に推定可能であるか評価を行う必要がある。本研究では、車線変更する場合における評価を行う際、提案手法により車線変更すると推定された時刻 τ_{est} と車が中央線に接する時刻 τ_{ch} との差を τ_{gap} と定義し、推定性能評価の指標とした。評価指標 τ_{gap} は値が大きいほど、早く車線変更を推定できることを示し、優れた推定性能を持つことを意味する。表 2 にその評価結果を示す。解析結果、推定時間差 τ_{gap} は平均 2.2 秒であり、遅くても他車が中央線に接する 1.9 秒前には車線変更を推定することが可能であった。

提案手法より得られた推定結果と従来手法による結果との比較を行った。以下に示す従来手法の推定性能は実車実験を行った結果であり、提案手法の評価デー



(a) 特徴量の変化



(b) 提案手法による推定結果

Fig. 5 評価データにおける推定結果

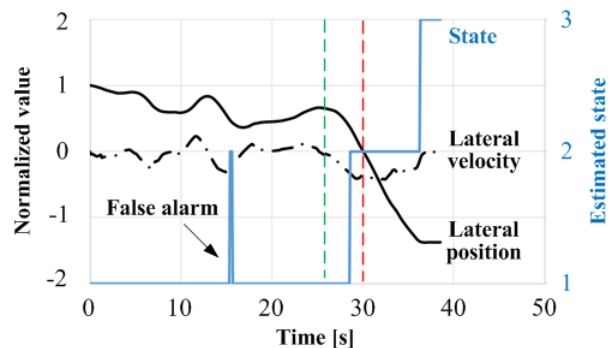


Fig. 6 False alarm が発生する様子

タとは異なるデータから得られた値である。そのため、公正な比較とは言えないが、提案手法の有効性を

評価する際の参照値として用いた。比較指標は推定時間差 τ_{gap} と推定精度を表す正確度を用いる。Kumarらは Support Vector Machine に Bayesian filter を適用した推定手法を提案し、実車による実験から自車の車線変更推定を行った結果、推定時間差 τ_{gap} は 1.3 秒であったと報告した⁽¹³⁾。その際における正確度は 71.5 %であった。また、Schlechtriemenらが提案した Naive Bayes Algorithm に Gaussian filter を適用した手法による他車における車線変更の推定時間差 τ_{gap} は 2.2 秒であり、正確度は 86.0 %が得られたと報告されている⁽⁷⁾。これに対し、提案手法は車線変更の推定時間差 τ_{gap} が 2.2 秒であり、正確度は 91.0 %である。以上の結果から、提案手法が推定精度と推定時間の両面におき、従来手法より優れた性能を持つことが示された。

4. 結 論

本研究では、隣車線の車が自車の先方へ割り込む場合を想定し、外部から測定可能な情報のみを用いた他車の車線変更推定手法の構築を行った。また、状態を認識単位とする HMM 構造の設計を行った。実際の交通データによる提案手法の有効性を評価した結果、従来手法より高い推定精度と早い推定時間性能を持つことを確認した。特に車線維持と車線変更を最も特徴付ける特徴量のみを用いることにより、従来手法では推定が不可能である MLC においても適切に推定可能であることが示された。

今後の課題としては、分岐点における車線変更である MLC2 の推定を行う際に発生する False alarm の低減があげられる。運転者が車線変更を行う意図を持っていても隣車線の状況により変更できないことが考えられる。隣車線を走行する車両との関係性を考慮することにより False alarm の発生を低減することを目指す。また、今回は交通データを用いた解析による手法の評価を行ったが、実用可能性を評価するためには計測装置を実装した車両による検証が必要であると考えられる。

参 考 文 献

- (1) 内閣府政策統括官, “SIP (戦略的イノベーション創造プログラム) 自動走行システム研究開発計画”, (2014).
- (2) R. Dang, F. Zhang, J. Wang, S. Yi and K. Li, “Analysis of chinese driver’s lane change characteristic based on real vehicle tests in highway”, *Proceedings of the 2013 IEEE International Conference on Intelligent Transportation Systems*, (2013), pp.1917-1922.
- (3) N. Kuge, T. Yamamura, O. Shimoyama and A. Liu, “A driver behavior recognition method based on a driver model framework”, *Society of Automotive Engineers*

- Transactions Journal of Passenger Cars*, Vol.109, No.6(2000), pp.469-476.
- (4) G. Li, S. E. Li, Y. Liao, W. Wang, B. Cheng and F. Chen, “Lane change maneuver recognition via vehicle state and driver operation signals - results from naturalistic driving data”, *Proceedings of the 2015 IEEE International Conference on Intelligent Vehicle Symposium*, (2015), pp.865-870.
- (5) A. Doshi and M. M. Trivedi, “On the Roles of Eye Gaze and Head Dynamics in Predicting Driver’s Intent to Change Lanes”, *IEEE Transactions on Intelligent Transportation Systems*, Vol.10, No.3(2009), pp.865-870.
- (6) 鈴木正裕, 稲垣伸吉, 鈴木達也, 早川総一郎, 土田縫夫, “視線情報とベイズ推定による運転行動意図の推定”, 電気学会 産業計測制御研究会, IIC-07-75, (2007), pp.29-34.
- (7) J. Schlechtriemen, A. Wedel, J. Hillenbrand, G. Breuel and K. D. Kuhnert, “A lane change detection approach using feature ranking with maximized predictive power”, *Proceedings of the 2014 IEEE International Conference on Intelligent Vehicle Symposium*, (2014), pp.108-114.
- (8) J. Ding, R. Dang, J. Wang and K. Li, “Driver intention recognition method based on comprehensive lane-change environment assessment”, *Proceedings of the 2014 IEEE International Conference on Intelligent Vehicle Symposium*, (2014), pp.214-220.
- (9) P. M. Baggenstoss, “A modified baum-welch algorithm for hidden markov models with multiple observation spaces”, *IEEE Transactions on Speech and Audio Processing*, Vol.9, No.4, (2001), pp.411-416.
- (10) J. Hagenauer and P. Hoehner, “A viterbi algorithm with soft-decision outputs and its applications”, *Proceedings of the 1989 IEEE International Conference on Global Telecommunications and Exhibition*, (1989), pp.1680-1686.
- (11) The Federal Highway Administration, U.S. Department of Transportation: “Next Generation Simulation”, <http://ops.fhwa.dot.gov/trafficanalysisistools/ngsim.htm>, (Access: 10 May 2015).
- (12) T. Toledo and R. Katz, “State dependence in lane-changing models”, *Journal of the Transportation Research Board*, No.2124(2009), pp.81-88.
- (13) P. Kumar, M. Perrollaz, S. Lefevre and C. Laugier, “Learning-based approach for online lane change intention prediction”, *Proceedings of the 2013 IEEE International Conference on Intelligent Vehicles Symposium*, (2013), pp.797-802.