

人工ポテンシャル法による周辺車両との関係性を考慮した車線変更推定

禹 ハンウル¹⁾ 池 勇勳¹⁾ 河野 仁¹⁾ 田村 雄介¹⁾ 山下 淳¹⁾ 浅間 一¹⁾ 菅野 崇²⁾ 黒田 康秀³⁾

Lane-Change Estimation Based on Relationship with Adjacent Vehicles Using Artificial Potential Method

Hanwool Woo Yonghoon Ji Hitoshi Kono Yusuke Tamura Atsushi Yamashita Hajime Asama
Takeshi Sugano Yasuhide Kuroda

A lane-change is the main cause of car crashes. Therefore, the lane-change estimation can reduce the accident rate. In this research, we propose an estimation method for lane-changes of other traffic participants. The main contribution in this research is to propose the new feature considering the relationship with adjacent vehicles. We represent the new feature using the dynamic characteristic potential field, and it can improve the estimation performance for the lane-change detection. We evaluated the performance using real traffic data. And we achieved a higher estimation accuracy and an earlier prediction time than previous methods.

KEY WORDS: Safety, Accident avoidance/Collision prediction, Intelligent/Computer application, Lane-change estimation(C1)

1. 序 論

交通事故は減少傾向にあるものの、未だに死亡事故の主な原因として残っている。警視庁の調査によると、交通事故の約9割以上が人為的要因により発生し、その約8割が運転者の対応ミスに起因する(1)。近年、交通事故の解決策として自動運転や運転支援システムに関する研究が注目されており、これらのシステムが運転者を補助することで、交通事故の発生を低減させることが期待されている。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。中国で行われた先行調査では、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)。この研究では、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らは自車の内部情報のみを用いた推定システムを提案し、SFSS(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)。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(6)。この研究では、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(7)。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ついては未検討の部分が多い。例えば、後続車からの急速な接近により車線変更を行う場合が考えられる。また、隣車線の方が空いており、車線変更を行うケースも存在する。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、前提条件以外においては周辺車両との相対量が外乱となる可能性が存在する。特徴量を追加する際、ある条件のみに特化した情報を含めると想定外の条件下では推定性能低下の原因となる。また、使用可能な全ての情報を用いるより有効な情報のみを選別し、特徴量として用いた方が高い推定性能が得られると先行研究から報告されている(6)。

以上の問題点を踏まえ、本研究では、他車が行う車線変更を想定し、動特性人工ポテンシャル法を用いることで、周辺車両との関係性を適切に記述可能な特徴量を新たに提案する。障害物からの斥力ポテンシャルを生成する際、本研究では、障害物の移動方向や速度も考慮する動特性モデルを用いる。この

1) 東京大学 (113-8656 文京区本郷7-3-1)

2) マツダ(株) (730-8670 広島県安芸郡府中町新地 3-1)

3) マツダ(株) (221-0022 神奈川県横浜市神奈川区守屋町 2-5)

動特性人工ポテンシャル法を車の走行特性に適用させ、周辺車両との相対量に応じて分布が変化する人工ポテンシャル場を生成する。その後、車線変更前の車線と変更後の車線におけるポテンシャルの比から車線変更推定に用いる特徴量を抽出する。新たに提案する特徴量は、従来手法が想定した先行車が遅い場合や隣車線の方が速い場合を含め、後続車の急接近により車線変更を行う場合や隣車線の方が空いているため車線変更する場合でも適用することができる。また、周辺車両との十分な車間距離が確保できず、車線変更を諦める場合にも適用可能である。

提案手法の構築および推定性能評価は、米国連邦運輸省が公開している交通データを用いて行う (8)。また、従来手法との推定性能比較を行い、提案手法の有効性を検証する。

2. 人工ポテンシャル生成

2.1. 人工ポテンシャル法

ポテンシャル法はロボットの経路計画でよく用いられる手法であり、目的地からは引力ポテンシャルが発生し、障害物からは斥力ポテンシャルが生成される。次に人工ポテンシャルの基本モデルを示す。

$$U = U_d + U_o \quad (1)$$

ここで、 U_d は目的地からの引力ポテンシャル、 U_o は障害物からの斥力ポテンシャルを表す。障害物からの斥力ポテンシャルは次式となる。

$$U_o = \frac{1}{2\pi\sigma^2} \exp\left[-\frac{r}{2\sigma}\right] \quad (2)$$

ただし、 r はロボットから障害物までの距離、 σ は距離の分散量である。上記の基本モデルは障害物との距離のみを考慮しており、動的障害物は想定していない。これに対し、星野らは動的障害物の移動方向と速度を考慮した人工ポテンシャル法を提案した (9)。この手法は障害物の動特性をフォン・ミーゼス分布によりモデル化することで、障害物の移動方向に偏った分布を持つ人工ポテンシャル場を生成する。図 1 に基本モデルと動特性モデルが生成する人工ポテンシャル場の様子を示す。本研究では、変更前車線および変更後車線の前後車両との車間距離、相対速度、相対角度に応じて分布方向が変化する人工ポテンシャルを生成する。図 2 に本研究で考慮する周辺車両と各車両における相対量を示す。車線変更推定の対象であり、車線変更を行う車を Target、現走行車線における先行

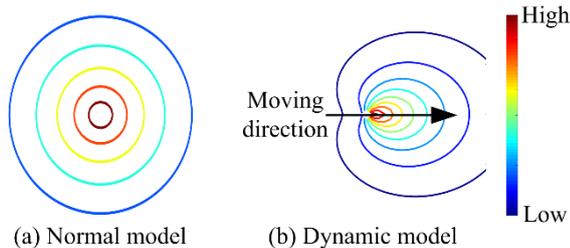
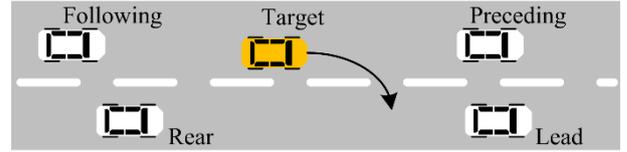
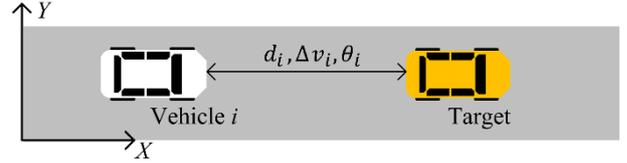


Fig.1 Potential field diagram



(a) Adjacent vehicles for artificial potential



(b) Relative amounts at vehicle i

Fig.2 Definition of adjacent vehicles and relative amounts

車を Preceding、後続車を Following、隣車線における先行車を Lead、後続車を Rear と定義し、これ以降、各車両を頭文字 (T, P, F, L, R) で表記する。車両 i における斥力ポテンシャルは次式で与えられる。

$$U_i = \frac{\exp[k(\Delta v_i)\cos\theta_i]}{2\pi I_0[k(\Delta v_i)]} \alpha \frac{\exp\left[-\frac{d_i}{2\sigma}\right]}{2\pi\sigma} \quad (3)$$

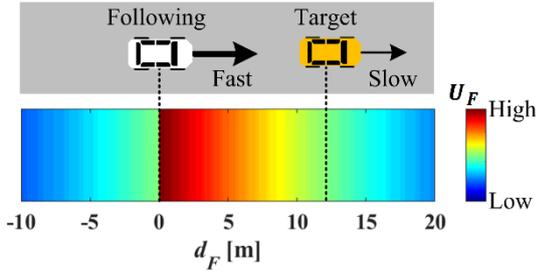
$$d_i = x_i - x_T \quad (4)$$

$$\Delta v_i = v_{i,x} - v_{T,x} \quad (5)$$

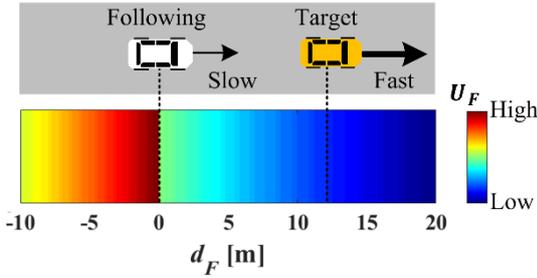
$$\theta_i = \begin{cases} 0 & (i = P, L) \\ \pi & (i = F, R) \end{cases} \quad (6)$$

ここで、 d_i は推定対象車との車間距離、 σ は車間距離の分散量、 Δv_i は推定対象車との相対速度、 θ_i は相対角度、 α は係数である。式(3)における第 1 項はフォン・ミーゼス分布を表しており、分母の $I_0(k)$ は第 1 種変形ベッセル関数である。フォン・ミーゼス分布はパラメータ k によって分布方向を調節することが可能であり、 $k=0$ のとき一様分布となる。本研究では、このパラメータ k を相対速度 Δv_i に依存する定数とし、推定対象車との速度差によってポテンシャルが高まる方向が決定される。また、車線に従って走行する車の特性から相対角度 θ_i は前後の位置関係により定まる 2 値とする。式(3)における第 2 項は、周辺車両との車間距離に反比例して生成される斥力ポテンシャルを表す。これにより、十分な車間距離が確保されていない場合、推定対象車は隣接車両から大きなポテンシャルを受けることとなる。

提案モデルにより生成される人工ポテンシャルの様子を変更前車線の後続車を例とし、図 3 に示す。後続車が推定対象車より速い場合、推定対象車の方へ伸びる人工ポテンシャル場が生成され、リスクが高まることとなる。後続車が遅い場合は後続車の後方へ伸びる人工ポテンシャル場が生成され、推定対象車は後方からの圧力を受けないこととなる。本研究では、車線に従って走る車両走行特性を反映し、車線方向である X 軸方向のみを考慮する 1 次元の人工ポテンシャル場を生成する。そのため、同車線においては Y 軸方向の車両位置に依



(a) Following vehicle is faster than target vehicle



(b) Following vehicle is slower than target vehicle

Fig.3 Differences of potential field by relative velocity

存しない人工ポテンシャル場が生成される。隣車線における前後車両からの人工ポテンシャルを生成する際には、推定対象車が現在の X 座標のまま隣車線上を走行していると仮定し、相対量を求める。

2.2. 特徴量抽出

周辺車両との相対量から求められる人工ポテンシャルは車線ごとに加重和で統合し、現走行車線と変更先車線における人工ポテンシャルの比から特徴量を抽出する。本研究では、2車線を想定し、問題を定義したが、3車線における車線変更推定を行う際には、推定対象車を中心とした左右の車線に対し、同様の手法を適用することが可能である。各車線における人工ポテンシャルは次式で与えられる。

$$U_C = \omega_P U_P + \omega_F U_F \quad (0 \leq U_C \leq 1) \quad (7)$$

$$U_N = \omega_L U_L + \omega_R U_R \quad (0 \leq U_N \leq 1) \quad (8)$$

ただし、 U_C は現走行車線における人工ポテンシャル、 U_N は隣車線における人工ポテンシャル、 ω_i は車両 i における重み係数である。算出したポテンシャルはその比に対数関数をかけ、累積分布関数を用いることで特徴量 p を抽出する。次に特徴量 p の抽出式を示す。

$$z = \ln U_C - \ln U_N \quad (9)$$

$$p = \phi[z] \quad (10)$$

ここで、 $\phi[\cdot]$ は累積分布関数を表す。以上の過程から求められた p が本研究で新たに提案する特徴量であり、周辺車両との関係性を車線変更推定に反映する情報となる。特徴量 p は現走行車線と隣車線の状況を比較することにより車線変更の可能性を評価するものであり、その値が表す意味を図4に示す。

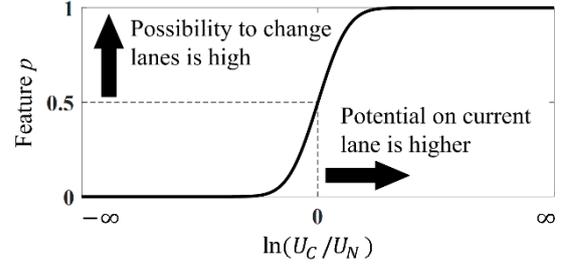


Fig.4 Feature p extracted by proposed potential model

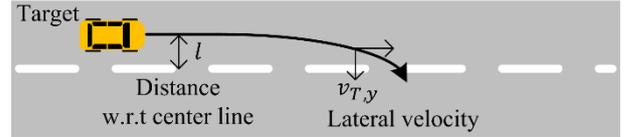


Fig.5 Features extracted from driving trajectory

現車線における人工ポテンシャル U_C が隣車線における人工ポテンシャル U_N より大きい場合、人工ポテンシャル比を因子とする自然対数は0以上となり、特徴量 p は0.5を超える値となる。これは現走行車線を走行する方が周辺車両から受けるリスクが高く、隣車線へ車線変更した方が有利であることを表す。

特徴量 p に加え、走行軌道から抽出される白線からの距離 l 、その1次微分項である $v_{T,y}$ の3つを推定手法の特徴量とする。ここで $v_{T,y}$ は推定対象車の車線垂直方向の速度である。白線からの距離 l 、車線垂直速度 $v_{T,y}$ は車線変更を最も特徴づける状態量であり、全車線変更において共通した変化様子を表す情報である。図5に白線からの距離 l 、車線垂直速度 $v_{T,y}$ の定義を示す。特徴量として推定対象車の Y 座標ではなく、白線からの距離を用いることにより、直線道路のみにならず、様々な道路形状に対応させることが可能である。本研究で用いる特徴ベクトル \mathbf{x} を次式で定義する。

$$\mathbf{x} = [l \quad v_{T,y} \quad p]^T \quad (11)$$

計測装置により測定される情報にはノイズが含まれることが予想されるため、移動平均フィルタを用い、ノイズの縮小を行う。その後、特徴量間の単位の大きさによる影響差を防ぐため、正規化を行う。しかし、オンラインで推定を行う際には現時刻までの計測値しか用いることができず、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。そのため、本研究では、各特徴量の最大値による正規化を行う。白線からの距離 l は車線中央までの距離を最大値とし、車線垂直速度 $v_{T,y}$ は全学習データの中から最大値を探索する。

3. 推定手法

3.1. 推定モデルの構築

抽出した特徴量から車線変更推定を行う手法として隠れマ

ルコフモデルを用いる。このモデルは、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可能である手法である。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、Ergodic 構造を持つ HMM を設定し、状態 i から状態 j へ遷移する確率 a_{ij} は一様とする。また、状態 i における特徴ベクトル \mathbf{x} が得られる確率 $b_i(\mathbf{x})$ はガウス分布に従うと仮定する。確率 $b_i(\mathbf{x})$ は次式から求められる。

$$b_i(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^k |\Sigma_i|}} \exp\left[-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu}_i)^T \Sigma_i^{-1} (\mathbf{x} - \boldsymbol{\mu}_i)\right] \quad (12)$$

ただし、 $\boldsymbol{\mu}_i$ は状態 i における平均値ベクトル、 Σ_i は状態 i における共分散行列である。各状態における平均値ベクトル $\boldsymbol{\mu}_i$ と共分散行列 Σ_i の初期値はランダムに設定する。初期化された HMM は学習によりパラメータが再推定される。本研究では、パラメータの再推定手法として Baum-Welch アルゴリズムを用いる。状態 i から状態 j へ遷移する確率 a_{ij} は次式となる。

$$a_{ij} = P(s_{t+1} = j | s_t = i) \quad (13)$$

ここで、 s_t は時刻 t における状態を表す。時刻 t までの特徴ベクトル系列を $\mathbf{X}_{1:t} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_t]$ とし、モデル M が時刻 t で状態 i に達する確率 $\alpha_t(i)$ を導入する。

$$\alpha_t(i) = P(\mathbf{X}_{1:t}, s_t = i | M) \quad (14)$$

この $\alpha_t(i)$ は次式から求められ、前向き確率と呼ぶ。

$$\alpha_t(i) = \left[\sum_{j=1}^N \alpha_{t-1}(j) a_{ji} \right] b_i(\mathbf{x}_t) \quad (15)$$

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。

$$\beta_t(i) = P(\mathbf{X}_{t+1:T} | s_t = i, M) \quad (16)$$

ここで、 T は特徴ベクトルが計測された最後の時刻である。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、次式から求まる。

$$\beta_t(i) = \sum_{j=1}^N a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(j) \quad (17)$$

以上の前向き確率 $\alpha_t(i)$ と後ろ向き確率 $\beta_t(i)$ を用い、HMM パラメータの再推定を以下の式から行う。

$$\bar{a}_{ij} = \frac{\sum_{t=1}^{T-1} \alpha_t(i) a_{ij} b_j(\mathbf{x}_{t+1}) \beta_{t+1}(j)}{\sum_{t=1}^{T-1} \alpha_t(i) \beta_t(i)} \quad (18)$$

$$\bar{\boldsymbol{\mu}}_i = \frac{\sum_{t=1}^T \alpha_t(i) \beta_t(i) \mathbf{x}_t}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (19)$$

$$\bar{\Sigma}_i = \frac{\sum_{t=1}^T \alpha_t(i) \beta_t(i) (\mathbf{x}_t - \bar{\boldsymbol{\mu}}_i)(\mathbf{x}_t - \bar{\boldsymbol{\mu}}_i)^T}{\sum_{t=1}^T \alpha_t(i) \beta_t(i)} \quad (20)$$

以上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。

3.2. 車線変更推定手法

構築したモデルを用い、他車の車線変更可能性を判断する際には、現時刻における他運転者の意図が属する HMM の内部状態を推定する。本研究では、HMM の内部状態推定手法として Viterbi アルゴリズムを用いる。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。

$$\delta_t(i) = \max_i P[\mathbf{S}_{1:t-1}, s_t = i, \mathbf{X}_{1:t} | M] \quad (21)$$

ここで、 $\mathbf{S}_{1:t-1}$ は時刻 $t-1$ までの状態系列である。 $\delta_t(i)$ は以下の式から再帰的に求めることができる。

$$\delta_t(i) = \max_i P[\delta_{t-1}(i) a_{ij}] b_j(\mathbf{x}_{t+1}) \quad (22)$$

現時刻 t における最尤な状態 s_t は次となる。

$$s_t = \arg \max_i \delta_t(i) \quad (23)$$

推定された状態 s_t が車線変更を意味する内部状態である場合、提案手法は最終的に推定対象車が車線変更を行うと判断する。

4. 計算機実験

4.1. 提案特徴量 p の検証

新たに提案する特徴量 p が様々な車線変更条件を適切に記述できるかを評価するため、以下の 10 項目を仮定し、各場面における特徴量 p の値を算出した。その結果を図 6 に示す。

- (a) Preceding が Target より遅い場合
- (b) Preceding が Target より速い場合
- (c) Lead が Preceding より速い場合
- (d) Lead が Preceding より遅い場合
- (e) Following が Target より速い場合
- (f) Following が Target より遅い場合
- (g) 隣車線の方が空いている場合
- (h) 現車線の方が空いている場合
- (i) Preceding が遅く、Rear が Target より遅い場合
- (j) Preceding が遅く、Rear が Target より速い場合

解析結果、車線変更を行った場合が有利である場合 (a, c, e, g) には 0.5 以上の値が算出され、車線変更を行わない方が有利である場合 (b, d, f, h) には 0.5 未満の値が算出された。また、(i) と (j) は車線変更を行う際における危険度を評価する項目であり、隣車線の後続車が速い速度で接近する場合や十分な車間距離が確保出来ない場合は、隣車線の方が有利であっても車線変更を行うことは危険であると考えられる。項目 (i) は隣車線の後続車が推定対象車より遅いため、車線変更が可能となり、特徴量 p は 0.5 以上となった。これに対し、項目 (j) は、隣車線の後続車が速く接近するため、特徴量 p が 0.5 未満となることが確認できる。

以上の結果から、提案特徴量 p は周辺車両との関係性を適切に反映し、様々な条件下で行われる車線変更を有効に記述することが可能であると考えられる。

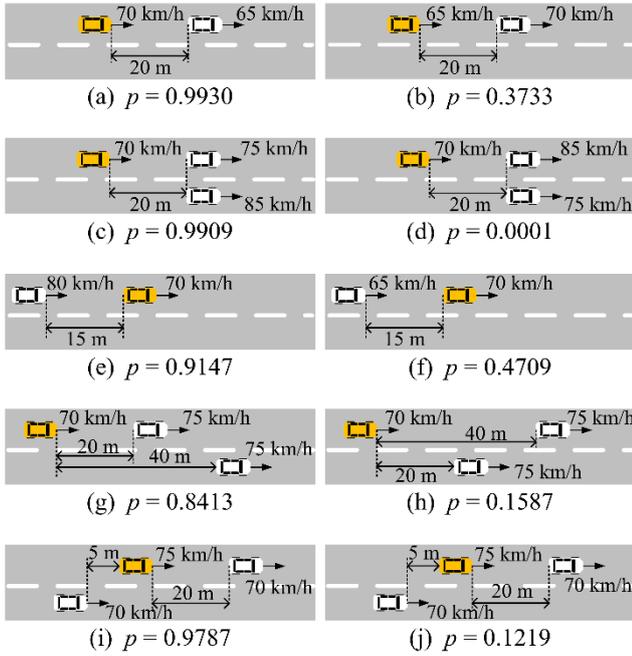


Fig.6 Feature p values at lane-change situations

4.2. 推定性能評価方法

提案手法の構築および推定性能評価には、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を用いた(8)。測定はCalifornia州のEmeryvilleに位置するI-80道路で行われた。7台のカメラが30階の建物上に設置され、15分間の交通流を0.1秒刻みに記録したデータが3セット公開されている。道路は約500mの直線区間が6車線で構成されている。計測された車両数は総5,678台であり、車線変更を行った車両は958台であった。本研究では、提案手法の学習に300台の車線変更データを使用し、658台の車線変更データを推定性能評価に用いた。学習データにおけるクラスのラベリングは著者が手動で行った。

本研究では、先行研究と同様の推定精度を表す F_1 と早期認識性能を評価する推定余裕時間 τ_p の2つの評価指標を用い、提案手法の推定性能評価を行った。まず、推定精度指標である F_1 値は次式から求められる。

$$precision = \frac{TP}{TP+FP} \quad (24)$$

$$recall = \frac{TP}{TP+FN} \quad (25)$$

$$F_1 = 2 \times \frac{precision \times recall}{precision + recall} \quad (26)$$

ここで、 TP は提案手法より正しく車線変更すると推定されたケースの数、 FP は車線変更しないケースを提案手法より車線変更すると誤推定されたケースの数、 FN は車線変更するケースを提案手法が車線変更しないと判断したケースの数である。

早期認識性能を評価する推定余裕時間 τ_p は、提案手法より

車線変更すると推定された推定時刻を τ_e 、推定対象車の中心が白線を越える車線変更時刻を τ_c と定義し、その差から求める。

$$\tau_p = \tau_c - \tau_e \quad (27)$$

推定余裕時間 τ_p が大きい値になるほど優れた早期認識性能であることを意味し、単位は秒となる。上記を用いて車線変更推定の成敗基準を以下の様に設定した。

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

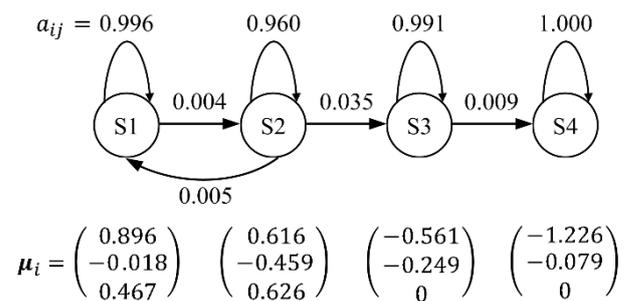
一般的に車線変更は3.0秒から5.0秒以内に行われると報告されている。本研究では、先行研究の調査結果を参考とし、推定余裕時間 τ_p が5.0秒を超えた場合をFalse alarmであると判定した。

4.3. 提案手法の推定性能評価

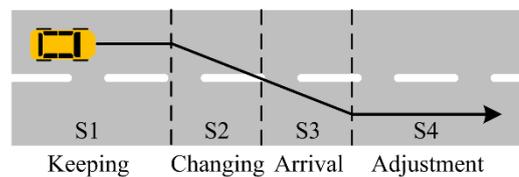
学習データから構築された推定モデルを図7に示す。本研究では、HMMの内部状態数を増やしながら学習を行い、最も高い推定性能を有するモデルを採択した。本研究では、図7(a)のような4つの内部状態で構成されるモデルを用いた。内部状態 i における平均値ベクトル μ_i から各内部状態が以下に示す運転者意図を表すと定義した。

- S1 : Keeping - 現在の車線を維持する
- S2 : Changing - 車線変更を実行する
- S3 : Arrival - 白線を越え、目標車線の中央へ向かう
- S4 : Adjustment - 前後車両と速度を合わせる

構築されたモデルは左から右へと遷移するLeft-to-Right構造となり、車線変更を試みたものの、周辺車両との関係から車線変更を諦め、車線維持へと戻る状態遷移構造も確認された。



(a) Trained estimation model



(b) Driver's intention model

Fig.7 Proposed lane-change estimation model

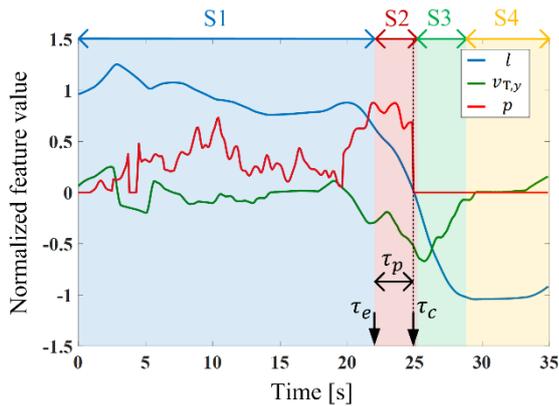


Fig.8 Estimation result by proposed method

Table.1 Performance comparison

Mandalia		Schlechtriemen		Proposed method	
F_1 [%]	τ_p [s]	F_1 [%]	τ_p [s]	F_1 [%]	τ_p [s]
80.4	1.37	96.8	1.68	97.5	1.89

本研究では、推定された内部状態が「Keeping」から「Changing」へ遷移する時刻を推定時刻 τ_e とした。車線変更時刻 τ_c は交通データから与えられる。1台の車線変更データにおける特徴量の変化履歴を図8に実線で示す。また、提案手法より推定された内部状態を図8に塗り色で示す。黒い破線は、推定対象車が中央線を越える車線変更時刻 τ_c を表しており、白線からの距離 l が0となる時刻である。提案手法から推定された内部状態がS1からS2となる時刻が推定時刻 τ_e であり、車線変更時刻 τ_c より早く推定されたことが確認できる。車線変更時刻 τ_c と推定時刻 τ_e の差が推定余裕時間 τ_p であり、この評価データの場合、2.9秒であった。図8から提案特徴量 p が車線変更時刻 τ_c の前に上昇することが確認できる。車線変更後は変更前車線における人工ポテンシャルを考慮する必要がないため、特徴量 p は0とした。

以上の解析を全車線変更データに対して行い、従来手法との推定性能比較を行った。Mandaliaらが提案した手法は、走行軌道のみを特徴量として用いる(10)。Schlechtriemenらが提案した手法は、走行軌道に加え、先行車との相対速度を特徴量とする。提案手法は、走行軌道と新規特徴量 p を用いており、この比較から特徴量 p の有効性が評価できる。厳密な性能比較を行うため、従来手法を実装し、同じ評価データを用いて推定性能を求めた。その結果を表1に示す。解析の結果、本研究の提案手法が推定精度および早期認識性能の両評価指標において最も高い推定性能を有することが示された。

5. 結論

本研究では、他車の車線変更を認識する運転支援システム

や自動運転を想定し、外部から計測可能な情報のみを用いる車線変更推定手法の構築を行った。周辺車両との相対量に応じて分布が変化する人工ポテンシャルを生成し、現走行車線と隣接車線におけるポテンシャル比から特徴量の抽出を行った。これにより、ある車線変更条件に特化した従来手法の特徴量に対し、提案特徴量は、様々な条件下で行われる車線変更を適切に記述可能であることを確認した。その結果、従来手法より推定精度および早期認識性能の両面において優れた推定性能が得られることを確認した。

今後は提案手法の実用化可能性を検討するため、カメラやレーザースキャナなどの計測装置を実装した車両による計測実験を行い、得られたデータにより提案手法の有効性評価を計画している。

参考文献

- (1) 警視庁：交通事故の違反別発生状況, (2014)
- (2) R. Dang et al. : Analysis of Chinese driver's lane change characteristic based on real vehicle tests in highway, Proceedings of the IEEE International Conference on Intelligent Transportation Systems, pp.1917-1922 (2013)
- (3) N. Kuge et al. : A driver behavior recognition method based on a driver model framework, Society of Automotive Engineers Transactions Journal of Passenger Cars, Vol.109, No.6, pp.469-476 (2000)
- (4) G. Li et al. : Lane change maneuver recognition via vehicle state and driver operation signals-results from naturalistic driving data, Proceedings of the IEEE International Conference on Intelligent Vehicle Symposium, pp.865-870 (2015)
- (5) A. Doshi et al. : 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, pp.453-462 (2009)
- (6) J. Schlechtriemen et al. : A lane change detection approach using feature ranking with maximized predictive power, Proceedings of the IEEE International Conference on Intelligent Vehicle Symposium, pp.108-114 (2014)
- (7) J. Ding et al. : Driver intention recognition method based on comprehensive lane-change environment assessment, Proceedings of the IEEE International Conference on Intelligent Vehicle Symposium, pp.214-220 (2014)
- (8) The Federal Highway Administration : U.S. Department of Transportation, Next Generation Simulation, <http://ops.fhwa.dot.gov/trafficanalysistools/ngsim.htm>, (Access: 10 May 2015)
- (9) S. Hoshino et al. : 人の動特性とロボットの混雑を考慮した人工ポテンシャル法の提案, 第26回自律分散システム・シンポジウム, pp.11-16 (2014)
- (10) H. Mandalia et al. : Using support vector machines for lane change detection, Proceeding of the Human Factors and Ergonomics Society, pp.1965-pp.1969 (2005)