

車線変更推定法および人工ポテンシャル法を用いた他車の走行軌道予測

禹 ハンウル (東京大学), 池 勇勳 (東京大学), 河野 仁 (東京大学), 田村 雄介 (東京大学),
黒田 康秀 (マツダ), 菅野 崇 (マツダ), 山本 康典 (マツダ), 山下 淳 (東京大学), 浅間 一 (東京大学)

Vehicle-Trajectory Prediction of Other Vehicles Using Lane-Change Estimation and Artificial Potential Field Method

Hanwool WOO (The University of Tokyo), Yonghoon JI (The University of Tokyo),
Hitoshi KONO (The University of Tokyo), Yusuke TAMURA (The University of Tokyo),
Yasuhide KURODA (Mazda), Takashi SUGANO (Mazda), Yasunori YAMAMOTO (Mazda),
Atsushi YAMASHITA (The University of Tokyo), and Hajime ASAMA (The University of Tokyo)

Abstract : We propose a new method to predict trajectories of other vehicles using the lane-change detection and the artificial potential field method. Previous methods do not consider surrounding vehicles when it predicts a trajectory of the target vehicle. The proposed method is able to predict a trajectory under crowded situation considering around vehicles by using the artificial potential field method. To evaluate the proposed method, we used a real traffic data and confirmed that the proposed method has the accurate performance.

1. 序論

警視庁が行った調査によると、約 90 %の交通事故が人為的な運転ミスにより発生するとされている [1]。そのため、自動運転および運転支援システムが交通事故低減に向けた解決策として注目されている。自車の周辺状況を認識し、危険な場面が予測された時、運転者に警告を鳴らすシステムは交通事故の低減に貢献できる。このような交通事故は車線変更を行う時によく発生すると先行研究で報告されている [2]。もし、他車が両車線における中央線を越える前に車線変更が検知され、運転者に知らせることが可能であれば、交通事故の低減に貢献できると予想される。そして車線変更推定のみならず、その走行軌道までを予測する研究が行われている。

Best らは、移動ロボットにおける軌道予測手法を提案した [3]。しかし、移動ロボットと自動車は走行特性が異なるため、この手法をそのまま車両の軌道予測に適用することは困難である。Wolf らは、人工ポテンシャル法を用いた車両の経路生成手法を提案した [4]。人工ポテンシャル法は、移動ロボットの経路を生成する際、よく用いられる手法である [5][6][7]。しかし、この手法を用いて経路を生成するためには、どれほど速く走りたいかを知る必要があるが、他車の希望速度を計測することは不可能である。そのため、他車の軌道予測に適用することは困難である。Houenou らは、運動モデルおよび軌道認識モデルによる他車の軌道予測手法を提案した [8]。この手法により、車線維持および車線変更における走行軌道を予測することが可能である。しかし、この手法は軌道を生成する際、周辺車両を考慮しな




Fig. 1: Driving intentions in lane-changing process.

いため、予測対象の周辺に多くの車両が走る複雑な環境の下では適切な軌道予測が行われないと考えられる。

以上の背景を踏まえ、本研究では車線変更推定および人工ポテンシャル法を用いた他車の軌道予測手法を提案する。提案手法は、外部計測可能な情報のみを用いて車線変更推定を行い、その推定結果を踏まえたポテンシャル場を生成する。また、ポテンシャル場を生成する際に他車の希望速度などの計測不可能な状態量を使用せず、走行挙動のみを用いる。これにより他車が行う車線維持および車線変更における走行軌道の予測を可能とし、予測対象の周辺車両も考慮に含めた高精度の軌道予測手法の構築を目指す。提案手法の有効性評価には、実際に計測された交通データを用いて提案手法より予測された軌道の精度を評価する。

2. 車線変更推定手法

提案手法における車線変更推定は、SVM (Support Vector Machine) による多クラスの識別問題として扱う。提案手法は、車線変更が図 1 に示すような 4 つの運転意図で構

成されると定義し、計測量から抽出された特徴量を用いて現時刻における運転者の意図が4つのクラス中、どこに属するかを識別する。SVMはカーネルを用いることにより低次元の特徴量を高次元へ変換することが可能である。そのため、高次元の特徴量空間に分布すると予想される運転者の意図推定問題に有効であると先行研究で報告されている[9][10]。識別モデルの構築には実際の交通データを用いる。この節では、提案手法で使用する特徴量の定義およびSVMによる識別法について詳細に記述する。

2.1 特徴量の定義

本研究では、車線変更推定に用いる特徴量として中央線からの距離 d 、垂直速度 \dot{d} 、現車線と隣接車線におけるポテンシャル比 p の3つを定義する。時刻 t における特徴量ベクトル \mathbf{x}_t は次式となる。

$$\mathbf{x}_t^{(k)} = \left[\mathbf{d}_t^{(k)} \quad \dot{\mathbf{d}}_t^{(k)} \quad \mathbf{p}_t^{(k)} \right]^T \quad (1)$$

$$\mathbf{d}_t^{(k)} = \left[d_{t-(W-1)}^{(k)} \quad \dots \quad d_{t-1}^{(k)} \quad d_t^{(k)} \right] \quad (2)$$

$$\dot{\mathbf{d}}_t^{(k)} = \left[\dot{d}_{t-(W-1)}^{(k)} \quad \dots \quad \dot{d}_{t-1}^{(k)} \quad \dot{d}_t^{(k)} \right] \quad (3)$$

$$\mathbf{p}_t^{(k)} = \left[p_{t-(W-1)}^{(k)} \quad \dots \quad p_{t-1}^{(k)} \quad p_t^{(k)} \right] \quad (4)$$

ここで、 k は車線変更の基準となる k 番目の白線を示すものである。提案手法は左方向の車線変更と右方向の車線変更の両方に適用することが可能である。車線変更方向により k 番目の白線が中央線として定まり、すべての特徴量が算出される。ここでの中央線は現車線と変更先の車線間にある白線を指す。図2のように車両が進み、左方向へ車線変更をする場合、 k 番目の白線が中央線として選定される。また、車線変更は連続性のある過程であるため、時系列データとして捉える必要がある。提案手法は、一定の時間幅内における特徴量を時系列データとして用いる。式(2)から式(4)における W はその時間幅を表すものである。本研究では、周囲 50 m 内の車両に対して車線変更推定を行うと想定しており、この範囲内における道路形状は急激に変化しないという仮定から白線の形状を最小2乗法による2次曲線として近似する[11]。 k 番目の白線の近似曲線は以下の式で表される。

$$y^{(k)} = a_2^{(k)}(x^{(k)})^2 + a_1^{(k)}x^{(k)} + a_0^{(k)} \quad (5)$$

ここで、 $a_2^{(k)}$ 、 $a_1^{(k)}$ 、 $a_0^{(k)}$ は k 番目の白線における係数である。提案手法は、0.1 m 間幅で近似曲線上の点群を生成し、推定対象車の位置 (x_T, y_T) と最も近い点からの距離を1つ

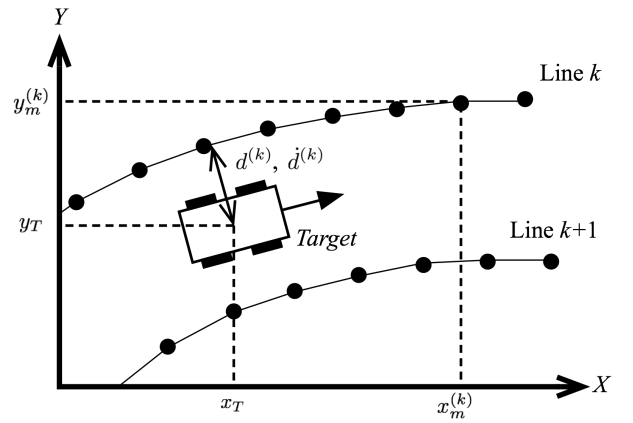


Fig. 2: Distance from centerline.

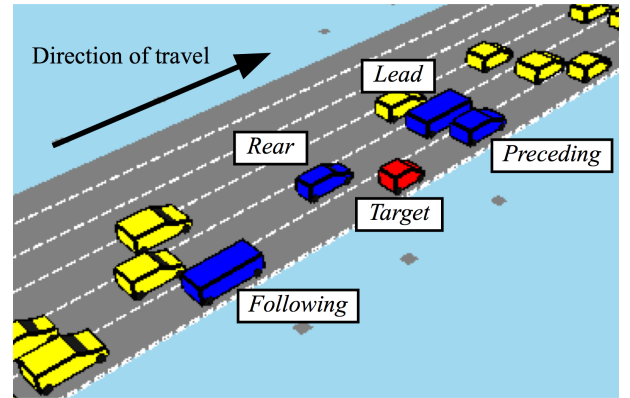


Fig. 3: Definition of adjacent vehicles.

目の特徴量である中央線からの距離 $d^{(k)}$ として定義する。中央線からの距離 $d^{(k)}$ は次式から定る。

$$d^{(k)} = \min\{f(m), m = 1, 2, \dots, M\} \quad (6)$$

$$f(m) = \sqrt{(x_T - x_m^{(k)})^2 + (y_T - y_m^{(k)})^2} \quad (7)$$

ここで、 m は k 番目の白線上における点群の番号を表す。中央線と推定対象車との関係を図2に示す。

2つ目の特徴量である垂直速度 $\dot{d}^{(k)}$ は、中央線からの距離を微分することで求めることができる。以上の2つの特徴量は単位を持っており、単位の大きさによる影響を抑えるためにはスケーリングを行う必要がある。本研究では、中央線からの距離においては車線の幅を、垂直速度においては学習過程に最大速度を算出して用いる。

3つ目の特徴量としては、現車線と隣接車線におけるポテンシャル比 $p^{(k)}$ を用い、次式で表される。

$$z = \ln U_C - \ln U_N \quad (8)$$

$$p^{(k)} = \varphi[z] \quad (9)$$

ここで、 $\varphi[\cdot]$ は累積分布関数であり、 U_C は現車線におけるポテンシャルエネルギーを、 U_N は隣接車線におけるポ

テンシャルエネルギーを表す．提案手法は，ポテンシャルエネルギーを算出する際に計測装置の計測範囲を考慮し，自車から最も近い車両を主に考慮する運転特性から図3に示すような4台の車両を対象とする．車線変更推定の対象車両を *target*，現車線における前方車量を *preceding*，現車線における後続車両を *following*，隣接車線における前方車両を *lead*，隣接車線における後続車両を *rear* と定義する．これ以降，4台の周辺車両は頭文字 (P, F, L, R) で表す．現車線と隣接車線におけるポテンシャルエネルギーは次式から求まる．

$$U_C = \omega_P U_P + \omega_F U_F, \quad (0 < U_C \leq 1) \quad (10)$$

$$U_N = \omega_L U_L + \omega_R U_R, \quad (0 < U_N \leq 1) \quad (11)$$

ここで， ω_i は車両 i に対する重み係数である．周辺車両 i が発するポテンシャルエネルギーは次式で表される．

$$U_i = \frac{\exp[\eta(\Delta v_i) \cos \theta_i] \exp[-\frac{r_i^2}{2\sigma_i^2}]}{2\pi I_0[\eta(\Delta v_i)]} \frac{1}{2\pi\sigma_i^2} \quad (12)$$

ここで， r_i は推定対象車との距離を， σ_i はその分散値を， Δv_i は推定対象車との相対速度を， θ_i は推定対象車との相対角度を表す．式(12)における左項は von Mises 分布であり， $I_0(\cdot)$ は0次のベッセル関数である．この von Mises 分布を用いることにより，相対速度および相対角度により偏りを持つポテンシャル場を生成することができる [12]．このポテンシャル場により周辺車両との関係性を表すことが可能となり，式(9)から求められるポテンシャル比 $p^{(k)}$ は車線変更が行われる状況を記述する特徴量となる．

2.2 車線変更推定手法

提案手法は SVM を用いることにより，現時点における運転者の意図を多クラス識別問題として扱う．SVM における境界平面パラメータの w と b は次式より求められる．

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (13)$$

ここで， $\phi(\mathbf{x})$ は特徴量空間への変換関数である．この境界平面のパラメータは学習過程により次式となる．

$$t_n(\mathbf{w}^T \mathbf{x}_n - b) \geq 1, \quad (n = 1, \dots, N) \quad (14)$$

ここで， n は学習データの番号を，特徴量ベクトル \mathbf{x}_n に対する t_n はクラスラベルを表す．SVM は特徴量空間において最大のマージンを持つように境界平面を設定する手法であり，最適なパラメータ \hat{w} と \hat{b} は次式から求まる．

$$(\hat{w}, \hat{b}) = \underset{w, b}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{w}\|^2 \quad (15)$$

この最適化問題は2次計画法により求めることができる [13]．学習により構築された識別モデルは，式(13)における符号により識別結果を判定する．以上の式は2クラス識別過程を表したものであり，提案手法は2クラス識別を各クラスごとに繰り返す one-versus-all 方式を用いて多クラスの識別を行う．最終的に現時点における運転者の意図が *changing* と判定された時，提案手法は推定対象車が車線変更を行うと判断する．

3. 他車の軌道予測手法

提案手法は，人工ポテンシャル法を用いて予測対象車の位置からゴールまでの経路を生成する．人工ポテンシャル法は，ゴールから引力ポテンシャルを，障害物から斥力ポテンシャルを生成させ，衝突せずにゴールまで到達可能な経路を生成することが可能である．提案手法は3つのポテンシャルエネルギーを定義し，位置 (x, y) におけるエネルギー和は次式となる．

$$U(x, y) = U_g + U_s + U_a \quad (16)$$

ここで， U_g はゴールからの引力ポテンシャルを， U_s は左右の白線からの斥力ポテンシャルを， U_a は周辺車両からの斥力ポテンシャルエネルギーを表す．まず，ゴールからの引力ポテンシャルエネルギーは次式により求まる．

$$U_g(x, y) = -\omega_{g_x} x - \omega_{g_y} y \quad (17)$$

ここで， ω_{g_x} と ω_{g_y} は重み係数である．次に k 番目の白線から発生する斥力ポテンシャルエネルギーの和は次式で表される．

$$U_s(x, y) = \omega_s \sum_k \exp\left[-\frac{(d^{(k)})^2}{\sigma_s^2}\right] \quad (18)$$

ここで， ω_s は重み係数を， σ_s はその分散を， $d^{(k)}$ は k 番目の白線からの距離を表す．最後に周辺車両から発生する斥力ポテンシャルエネルギーは次式となる．

$$U_a(x, y) = \omega_a \sum_{i=P,F,L,R} \exp\left[-\frac{(x-x_i)^2}{\sigma_{a_x}^2} - \frac{(y-y_i)^2}{\sigma_{a_y}^2}\right] \quad (19)$$

ここで， ω_a は重み係数であり， σ_{a_x} は X 軸方向における U_a の分散を， σ_{a_y} は Y 軸方向における U_a の分散を表す．このポテンシャルエネルギーの和から予測車両の位置 (x_T, y_T) で受ける力は次式となる．

$$\mathbf{F}(x_T, y_T) = -\left[\frac{\partial U(x_T, y_T)}{\partial x} \quad \frac{\partial U(x_T, y_T)}{\partial y}\right]^T \quad (20)$$

以上のポテンシャル場を生成する際，車線変更推定結果により異なる設定を行う．一般的に運転者は意図により




Fig. 4: Proposed potential field method considering driving intentions.




Fig. 5: Predicted trajectory by proposed method.

異なる戦略を持って運転を行うと考えられる．運転者が *keeping* と *adjustment* の意図を持つ時，走行車線の先を目指し，前後の車両との車間距離を保つことを試みる．これに対し，運転者の意図が *changing* と *arrival* である際には，隣接車線の先を目指し，走行車線および隣接車線における前後の車両を考慮しながら運転することとなる．提案手法はこのような戦略の違いを考慮し，図 4 に示すようなポテンシャル場を生成する．図 4(a) は車線変更推定結果が *keeping* である場合に生成するポテンシャル場を示したものである．現走行車線の前方にゴールを設定し，両サイドの白線から斥力ポテンシャルを発生させる．また，現走行車線を走る *preceding* と *following* 車両のみから斥力ポテンシャルを発生させる．これにより，現車線の中央を，前後の車両と車間距離を取りながら走行する軌道が予想される．これに対し，図 4(b) は車線変更推定結果が *changing* と *arrival* である場合に生成するポテンシャル場を示したものである．ゴールを隣接車線の前方に設定し，中央線からは斥力を発生させず，隣接車線の右側の白線から発生させる．また，現在の走行車線の周辺車両のみならず，隣接車線上を走行する周辺車両からも斥力ポテンシャルを発生させる．これにより，周辺車両を考慮しながら車線変更を行う軌道が生成される．最後に図 4(c) は車線変更推定結果が *adjustment* の場合に生成されるポテンシャル場を表したものである．ゴールを車線変更後の車線の前方に設定し，両サイドの白線から斥力ポテンシャルを発生させる．また，*lead* と *rear* 車両のみから斥力ポテンシャルを発生させる．これにより，車線変更先における前後の車両の速度に合わせながら車線を維持する軌道が生成される．以上の過程より運転意図を考慮した他車の走行軌道予測を行う．

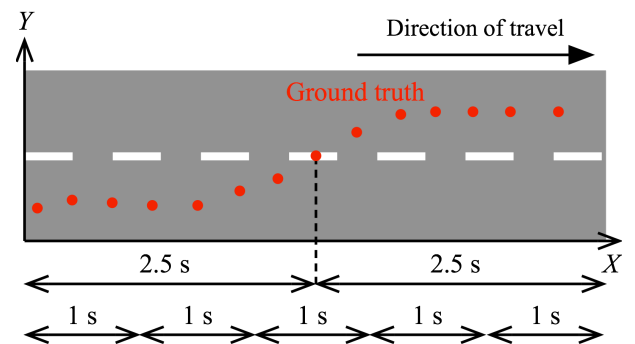


Fig. 6: Evaluation of proposed method.


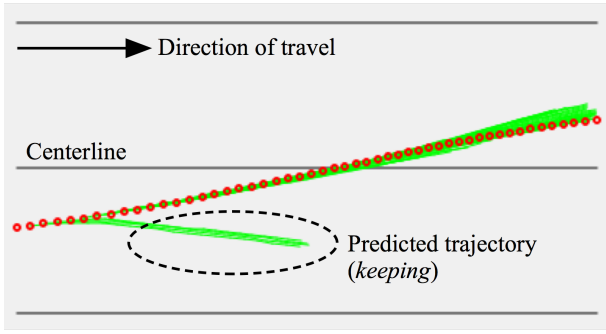



Fig. 7: Evaluation situation in heavy traffic.

4. シミュレーション実験


本研究では，アメリカの運輸省が公開している交通データを用いて車線変更推定の識別モデルおよび提案手法の有効性評価を行った [14]．使用した交通データは San Francisco Bay 地域における I-80 番道路を通る車両群を高層ビルの屋上からカメラにより計測したものである．道路は 6 車線，計測範囲は 500 m であり，0.1 秒ごとに 15 分間，3 回の計測が行われ，その結果，5,678 台の車両が計測された．その中，車線変更を行った車両を選別し，車線変更推定モデルの構築に 300 台の車線変更データを学習データとして用いた．また，提案手法の有効性評価には，213 台



(a) Average case.



(b) Minimum case.



(c) Maximum case.

Fig. 8: Results of trajectory prediction.

の車線変更データを用いた。

走行軌道予測におけるパラメータは、 $\omega_{g_x}=0.1$, $\omega_{g_y}=0.2$, $\omega_s=2.0$, $\sigma_s=1.1$, $\omega_a=12.2$, $\sigma_{a_x}=5.0$, $\sigma_{a_y}=17.4$, $\epsilon=2.0$ 秒のように設定した。図 5 に 1 つの評価データにおける軌道予測結果を示す。赤い車両が予測対象車両を、青い車両は軌道予測に考慮される 4 台の周辺車両を、黄色い車両は考慮に含まれない車両を表す。また、赤い線が実際予測対象車両が走行する真値の軌道を、緑の四角が各予測時刻における予測対象車両の予測位置を示したものである。図 5(a) は車線変更を行う前に現車線を維持している際の結果を表したものであり、図 5(b) は車線変更を行う際の予測結果である。最後に図 5(c) は車線変更を終え、前後の車両との速度を合わせている際の結果である。以上の結果から提案手法により適切な軌道が予測可能であることを確認した。

Table 1: Error of predicted trajectory

| AVG [m] | SD [m] | Min [m] | Max [m] |
|---------|--------|---------|---------|
| 0.98 | 0.11 | 0.34 | 2.67 |

Table 2: Error of predicted trajectory per section

| Time [s] | 0-1 | 1-2 | 2-3 | 3-4 | 4-5 |
|-----------|------|------|------|------|------|
| Error [m] | 1.45 | 0.99 | 0.83 | 0.81 | 1.16 |

厳密な評価を行うために各評価データにおける車線変更の際、真値と提案手法より予測された軌道との差を算出した。軌道予測は 0.1 秒ごとに行われ、予測対象車両が中央線を越える時刻を真ん中とした 5 秒間における位置差の平均値を算出した。位置差を算出する際の評価時間を 5 秒と設定したのは、車線変更が一般的に約 3 秒から 5 秒内に行われると先行調査により報告されているためである [15]。また、5 秒間の評価区間を 1 秒ずつに分け、各区間における誤差を算出した。軌道予測の精度を評価する区間を図 6 に示す。評価データは図 7 に示すような交通量が多いものを用い、混雑な環境下でも適切な軌道予測が可能であるか確認を行った。

全評価データにおける真値と提案手法より予測された位置との平均誤差、標準偏差、最小誤差、最大誤差を表 1 に示す。解析結果、予測軌道の平均誤差は 0.98 m、標準偏差は 0.11 m であった。また、最小誤差は 0.34 m、最大誤差は 2.67 m であった。図 8(a) に平均的な誤差を持つケースにおける真値に対する予測結果を、図 8(b) に最小誤差が得られたケースにおける結果を、図 8(c) に最大誤差となったケースにおける結果を示す。赤い点が各予測時刻における真値を、緑の線が提案手法より予測された軌道を表す。まず、図 8(a) から真値に沿って軌道が予測されたことが確認できる。しかし、最初の方においては車線変更推定の結果が *keeping* であったため、現車線を維持するような軌道が予測され、真値と離れた結果が得られた。図 8(b) の最小誤差が得られたケースの場合、ゆっくりと車線変更が行われたため、評価区間の開始時点で車線変更推定結果が *changing* となり、真値に沿った軌道が予測された。これに対し、最大誤差となった図 8(c) の場合、車線変更が遅く検知されたため、現車線を維持するような軌道が多く予測された。また、他のケースより急激な車線変更を行ったため、*changing* における予測軌道にも誤差が生じていることが確認できる。

以上の結果を踏まえ、軌道予測の精度向上のためには2つの改善点が考えられる。1つ目は車線変更推定法における早期認識精度の改善である。表2は評価区間を1秒ごとに分け、それぞれの区間内における推定精度を表したものである。この結果から評価区間の開始区間で最も誤差が大きくなったことが確認できる。これは車線変更が早期に検知できず、車線変更結果が *keeping* となり、現車線を維持するような軌道が予測されたことが要因である。しかし、車線変更推定において推定精度と早期認識性能はトレードオフ関係を持っており、両方を同時に向上させるのは極めて困難な問題である。早期認識性能のみを重視した場合、推定精度の劣化によりシステム全体への信頼性が落ちる恐れがある。多くの研究が車線変更推定性能の改善を目指して行われているが、高精度かつ中央線を越える2.5秒前に他車が行う車線変更を検知可能な手法はまだ提案されていないのが現状である [8][9][10][12]。

もう1つの改善策としては、運転者の特性を考慮した軌道予測が挙げられる。図8のように運転者はそれぞれ異なる軌道で車線変更を行うため、1つの平均的なモデルで予測を行うには限界があると考えられる。運転スキル、心理状態、周辺状況などの様々な理由により運転特性は変化され、異なる走行軌道として現れる。高精度の軌道予測のためには、車線変更を行う前までの走行挙動から予測対象の運転特性を推定し、軌道予測モデルに反映することが必要であると考えられる。また、走行挙動から運転特性を推定する手法の構築を今後の課題と設定し、取り組むことを計画している。

5. 結論

本研究では、車線変更推定法および人工ポテンシャル法を用いることにより、他車の走行軌道を予測することが可能な手法を構築した。従来手法では、外部からの計測が不可能な希望速度を用いることにより軌道予測を行った。また、周辺車両を考慮せずに軌道予測を行ったため、交通量が多い混雑な環境下では適切な予測が行われないと考えられる。これに対し、提案手法は外部から計測可能な他車の走行挙動のみを用いてポテンシャル場を生成する。また、周辺車両を考慮に含めたポテンシャル場を生成することで、混雑な環境下における軌道予測を可能とした。実際に計測された交通データを用いて提案手法の予測精度を評価した結果、平均0.98mの誤差を持って軌道を予測することが可能であることを確認した。

今後の課題としては、予測対象の走行挙動から運転特性を推定する手法の構築が挙げられる。推定された運転特性を軌道予測モデルに反映することで、より高精度な予測手法の構築を目指す。

参考文献

- [1] 警視庁, 交通事故の違反別発生状況, 2014.
- [2] U.S. Department of Transportation, Lane change /merge crashes: problems size assessment and statistical description, 1994.
- [3] G. Best and R. Fitch, Bayesian intention inference for trajectory prediction with an unknown goal destination, in *Proceedings of the 2015 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 5817-5823, 2015.
- [4] M. T. Wolf and J. W. Burdick, Artificial potential functions for highway driving with collision avoidance, in *Proceedings of the 2008 IEEE International Conference on Robotics and Automation*, pp. 3731-3736, 2008.
- [5] H. Chiang, N. Malone, K. Lesser, M. Oishi, and L. Tapia, Path-guided artificial potential fields with stochastic reachable sets for motion planning in highly dynamic environments, in *Proceedings of the 2015 IEEE International Conference on Robotics and Automation*, pp. 2347-2354, 2015.
- [6] V. A. M. Jorge, R. Maffei, G. S. Franco, J. Daltrozo, M. Giambastiani, M. Kolberg, and E. Prestes, Ouroboros: using potential field in unexplored regions to close loops, in *Proceedings of the 2015 IEEE International Conference on Robotics and Automation*, pp. 2125-2131, 2015.
- [7] Y. Ma, G. Zheng, W. Perruquetti, and Z. Qiu, Motion planning for non-holonomic mobile robots using the *i*-PID controller and potential field, in *Proceedings of the 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 3618-3623, 2014.
- [8] A. Houenou, P. Bonnifait, V. Cherfaoui, and W. Yao, Vehicle trajectory prediction based on motion model and maneuver recognition, in *Proceedings of the 2013 IEEE International Conference on Intelligent Robots and Systems*, pp. 4363-4369, 2013.
- [9] H. Mandalia and D. Salvucci, Using support vector machine for lane-change detection, in *Proceedings of the 2005 IEEE International Conference on Human Factors and Ergonomics Society*, pp. 1965-1969, 2005.
- [10] P. Kumar, M. Perrollaz, S. Lefevre, and C. Laugier, Learning based approach for online lane change intention prediction, in *Proceedings of the 2013 IEEE International Conference on Intelligent Vehicle Symposium*, pp. 797-802, 2013.
- [11] M. Thuy and F. P. Leon, Lane detection and tracking based on lidar data, *Metrology and Measurement Systems*, vol. 17, no. 3, pp. 311-321, 2016.
- [12] H. Woo, Y. Ji, H. Kono, Y. Tamura, Y. Kuroda, T. Sugano, Y. Yamamoto, A. Yamashita, and H. Asama, Dynamic potential-model-based feature for lane change prediction, in *Proceedings of the 2016 IEEE International Conference on Systems, Man, and Cybernetics*, 2016.
- [13] K. P. Bennett and E. J. Bredensteiner, Duality and geometry in SVM classifiers, in *Proceedings of the 17th International Conference on Machine Learning*, pp. 57-64, 2000.
- [14] The Federal Highway Administration, Next Generation Simulation, <http://ops.fhwa.dot.gov/traffic-analysis-tools/ngsim.htm> (accessed:10 May 2015).
- [15] T. Toledo and D. Zohar, Modeling duration of lane changes, *Transportation Research Record: Journal of the Transportation Research Board*, no. 1999, pp. 71-78, 2007.