

車両挙動分析による先行車追従における運転者の運転行動推定

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

Driving-Behavior Estimation Based on Vehicle-Following Behavior

Hanwool Woo Yonghoon Ji Hitoshi Kono Yusuke Tamura Yasuhide Kuroda Takashi Sugano
Yasunori Yamamoto Atsushi Yamashita Hajime Asama

Driving-intention estimation is attracting a lot of attention now, and it is expected to apply to the intelligent transport system. The main method is to construct an average model trained by enormous amounts of data, and the estimation is executed using the model. However, since a driver has his own characteristics, the average model might have the limitations. The proposed method focuses on the following behavior behind the preceding vehicle. Each driver shows different acceleration, deceleration, a gap between vehicles, and so on. Our method extracts the features from the following behavior and estimates the current driving behavior.

KEY WORDS: Human engineering, Driver condition, Driver model/rider model, Driving-behavior estimation (C2)

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ミスにより発生すると言われている (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おり、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が既に実用化されている。先行調査によると、交通事故は車線変更を行う時に多発する (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。

我々の研究グループは他車が行う車線変更を検知することが可能な手法を提案し、車線変更検知を識別問題として捉え、学習による識別モデルを構築した (3) . このようなアプローチは学習データに対する平均的なモデルが構築されることとなる。しかし、運転者は周辺環境や心理状態、運転スキルといった様々な要因に影響され、異なる運転行動をとるため、1つの平均的なモデルによる識別手法では限界があると予想される。そこで、現時点における運転者の運転行動を推定することが可能であれば、その結果に基づいて識別モデルを適応させるといったアプローチが考えられる。

三上らは先行車追従時における車両挙動から運転の危険度を評価する手法を提案し、網膜に映る先行車両の面積を表すリスク認知指標を新規に構築した (4) . しかし、この新規特徴量は相対速度に大きく依存し、不連続な値となる問題がある。Filev らは先行車両に追従する運転者を 2 次制御系として扱い、制御式における 2 つのゲイン係数と減衰率を特徴量と




Fig. 1 Problem Scenario

した識別手法を提案した (5) . この研究では、運転者の運転行動を「aggressive driver behavior」、「cautious driver behavior」、「super cautious driver behavior」の 3 つに定義し、識別性能の評価を行った。しかし、十分な識別精度が得られず、改善の余地が残る結果となった。

以上の背景を踏まえ、本研究では、先行車追従時における車両挙動から現時点における運転者の運転行動を推定する手法の構築を行う。また、動特性ポテンシャル法を用いることで連続的な値となる特徴量を新規に提案し、従来手法より優れた推定性能の達成を目標とする。動特性ポテンシャル法はある方向へ偏った分布を持つポテンシャル場を生成することが可能な手法である (6) . 本研究では、先行車から発生される斥力ポテンシャルエネルギーを動特性ポテンシャル法により算出し、特徴量として用いる。また、運転行動推定を識別問題として捉え、サポートベクトルマシン (support vector machine, SVM) により多クラス識別を行う。その際、過去の推定パターンを考慮した補正を行い、推定性能の向上を目指す。

2. 提案手法

2.1 問題定義

本研究で想定するシーンを図 1 に示す。赤い車が推定対象

1) 東京大学 (113-8656 文京区本郷 7-3-1)

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

3) マツダ(株) (730-8670 広島県安芸郡府中町新地 3-1)

車 (Target) を、青い車が推定対象車と同じ車線を走行する先行車 (Preceding) を、黄色い車が隣車線を走行する先行車 (Lead) を表す。本研究では、推定対象車が先行車に追従する際における挙動から運転行動を推定し、基礎的なシーンとして直線の自動車専用道路における推定手法の構築に取り組む。また、推定結果となる運転行動を“運転者の心理状況や目的といった様々な要因により最終的に現れる車両挙動”と定義し、「慎重」、「平常」、「急ぎ」の3つのクラスとする。提案手法は、現時点における運転者の運転行動が3つのクラスの中どこに属するかの推定を行う。

2.2 動特性ポテンシャル法を用いた特徴量抽出

本研究では、先行車に追従する際の危険度を表す特徴量を新規に提案し、動特性ポテンシャル法を用いて特徴量の抽出を行う。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エネルギーが発生し、障害物からは斥力ポテンシャルエネルギーが生成される(7)。次に人工ポテンシャル法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エネルギーを、 U_o は障害物からの斥力ポテンシャルエネルギーを表す。障害物からの斥力ポテンシャルエネルギーは次式となる。

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

ただし、 r は障害物までの距離、 σ_o は距離の標準偏差である。しかし、上記の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。動特性ポテンシャル法はフォン・ミーゼス分布を用いることで、障害物の移動方向に偏った分布を持つポテンシャル場を生成する。本研究では、先行車との車間距離、相対速度、相対角度に応じて分布方向が変化するポテンシャル場を生成する。

$$u = \frac{\exp[-\varepsilon(\Delta v)]}{2\pi I_0[\varepsilon(\Delta v)]} \alpha \frac{\exp\left[-\frac{d^2}{2\sigma^2}\right]}{2\pi\sigma^2} \quad (3)$$

ここで、 Δv は先行車 (Preceding) との相対速度を、 d は先行車との車間距離を表す。また、 σ は車間距離における分散を、 α は係数である。式(3)はフォン・ミーゼス分布と斥力ポテンシャルエネルギーの積算であり、 $I_0(\varepsilon)$ 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 ε によって分布方向を調節することが可能であり、 $\varepsilon = 0$ のとき一様分布となる。本研究では、このパラメータ ε を相対速度 Δv に依存する関




Fig. 2 Aspects of Proposed Potential Field : (a) a case when the target is slower than the preceding vehicle and (b) a case when the target is faster than the preceding vehicle

数とし、推定対象車との速度差によってポテンシャルエネルギーが高まる方向が決定される。式(3)の斥力ポテンシャルエネルギーの計算式により、十分な車間距離が確保されていない場合、推定対象車は先行車から大きなポテンシャルエネルギーを受けることとなる。本研究で提案する動特性ポテンシャル法を用いた特徴量は、連続的な値を得ることが可能であり、車間距離と相対速度の両方を適切に考慮することができる。図2に先行車との相対速度によって偏った分布を持つポテンシャル場の様子を示す。図2(a)は先行車が推定対象車より速く走行している場合であり、先行車の前方へ偏ったポテンシャル場が生成される。図2(b)は先行車が推定対象車より遅く走行している場合であり、推定対象車の方へ偏ったポテンシャル場が生成されることとなる。

提案手法では、先行車からの斥力ポテンシャルエネルギー u に加え、先行車との相対速度 Δv 、車間距離 d を特徴量として用いる。時刻 t における特徴ベクトル $\mathbf{x}_t$ は次式のように定義される。

$$\mathbf{x}_t = [\Delta \mathbf{v}_t^T \quad \mathbf{d}_t^T \quad \mathbf{u}_t^T]^T \quad (4)$$

$$\Delta \mathbf{v}_t = [\Delta v_{t-(N-1)}, \dots, \Delta v_{t-1}, \Delta v_t]^T \quad (5)$$

$$\mathbf{d}_t = [d_{t-(N-1)}, \dots, d_{t-1}, d_t]^T \quad (6)$$

$$\mathbf{u}_t = [u_{t-(N-1)}, \dots, u_{t-1}, u_t]^T \quad (7)$$

ここで N は時系列の特徴量を考慮するために設定したwindowの大きさを表す。提案手法は一定の大きさを持つwindowを設定することにより一連の流れから推定対象車の特性を推定する。

抽出された特徴量は数値の大きさや単位の影響を抑えるた

め、正規化を行う。本研究では、学習データから各特徴量の平均と標準偏差を求め、正規化を行った。

2.3 SVM による運転行動の識別

本研究では、運転者の運転行動推定を機械学習による識別問題として扱う。現在、機械学習による識別手法として様々な手法が提案されているが、中でも SVM は最も優れた識別精度を持つと言われている。この手法は学習データを用いて次式における重み係数 $\mathbf{w}$ とバイアス b を推定する。

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b \quad (8)$$

ここで $\phi(\mathbf{x})$ は特徴量を低次元の特徴空間に変換させる関数である。学習データにより識別境界面は次式を満たす。

$$t_n(\mathbf{w}^T \mathbf{x}_n - b) \geq 1, (n = 1, 2, \dots, N) \quad (9)$$

ここで n は学習データのインデックスを表し、 t_n は $\mathbf{x}_n$ に対するクラスのラベルである。SVMは両クラス間のマージンが最大となる境界面を設定する。式(9)を満たしながらマージンを最大化させるのは次式となる。

$$\underset{\mathbf{w}, b}{\operatorname{argmax}} \frac{1}{2} \|\mathbf{w}\|^2 \quad (10)$$

この最適化問題はquadratic programmingにより解くことができる (8)。提案手法は非線形の識別問題で最も広く用いられるradial basis functionを使用する。この関数は次式で表される。

$$K(\mathbf{x}, \mathbf{x}') = \exp(-g \|\mathbf{x} - \mathbf{x}'\|^2) \quad (11)$$

ここで g はカーネルのパラメータであり、 $\mathbf{x}'$ は学習データにおける特徴量ベクトルを表す。提案手法は2クラス識別を拡張したone-versus-all戦略を用いることで、多クラスの識別を行う。これにより時刻 t における運転行動は次式で求められる。

$$B_t = \underset{j=C,N,H}{\operatorname{argmax}} y_j(\mathbf{x}_t) \quad (12)$$

ここで j は運転行動のクラスを表すインデックスであり、「慎重」を C 、「平常」を N 、「急ぎ」を H で表す。

2.4 過去の推定パターンを考慮した推定精度の改善

本研究では、運転行動の推定精度を改善するためのフィルタ処理を新規に提案する。SVMはクラス間に極めて小さな差がある場合でも、必ず優先順位をつけて最終的に1つのクラスのみを出力する。このようなSVMの欠点を補うため、本研究では、クラスの判断が難しい場合に現時刻までの推定結果を統計的に参照するアプローチを取る。





Fig. 3 Driving Simulator : (a) a systematic diagram and (b) a picture of the driving simulator

KumarらはSVMの出力にベイジアンフィルタを適応することで、識別精度を改善した (9)。しかし、この手法は学習データにおける統計量を参照することとなる。これに対し、本研究で提案するフィルタは、実際の推定対象における現時刻までの推定結果から統計量を算出する。そのため、より優れた適応性を持つと考えられる。SVMから出力される時刻 t におけるクラス B_t の条件下で特徴ベクトルが現れる確率が $P(\mathbf{X}_{0:t}|B_t)$ である場合、提案フィルタは次式のようにその確率を補正する。

$$P'(\mathbf{X}_{0:t}|B_t) = P(\mathbf{X}_{0:t}|B_t) \frac{f(B)}{\sum_{B=C,N,H} f(B)} \quad (13)$$

ここで $P'(\mathbf{X}_{0:t}|B_t)$ はフィルタにより補正される確率を表し、 $f(B)$ はクラス B であると推定された回数である。最終的に推定されるクラスは次式となる。

$$B'_t = \underset{B_t=C,N,H}{\operatorname{argmax}} P'(\mathbf{X}_{0:t}|B_t) \quad (14)$$

本研究では、SVMの出力から判断が難しい場合に過去の推定パターンを考慮した補正を行う。これはすべての出力に対して補正を行うと最初に出たクラスに偏った補正が行われるためである。クラス間の確率差が小さいと判断する閾値は試行錯誤により定める。




Fig. 4 Experimental Scenario : (a) a case that the target follows the preceding vehicle, (b) a case that the lead vehicle accelerates and (c) a case that the preceding vehicle accelerates

3. 実験および評価

3.1 実験

本研究では、識別モデルを構築するための学習データと提案手法の推定性能を評価するための評価データを三菱プレジジョン社の D3 Sim というドライビングシミュレータ (Driving Simulator, DS) を用いて取得した。本研究で用いる DS は 3 次元視覚情報を前方の模擬視界表示装置に提示する。また、ステアリング、アクセル、ブレーキで構成される運転席を構築した。データ取得に用いた DS を図 3 に示す。図 3(a) は DS のシステム構成図を表したものであり、図 3(b) は実際に使われた DS の写真である。データは 120 Hz の記録周期で取得された。なお、本研究で行ったすべての被験者実験は、実験開始前にインフォームドコンセントを得て行った。

被験者が運転を行う環境としては、片側 2 車線の無限遠に伸びる直線のみ的高速道路を構築した。図 4 に走行環境を示す。赤い車は被験者が運転する車 (Target) を、青い車 (Preceding) と黄色い車 (Lead) は先行車を表す。被験者が運転する車の前方には両車線において先行車が走行する。図 4(a) に示すように 60 秒間 2 台の先行車は道を防ぐような形で走行し、被験者が先行車に追従するよう誘導した。この際、先行車はランダムで速度を変えながら走行するため、被験者は先行車との車間距離および速度を調節しながら運転する必要がある。60 秒の追従後には 2 台の先行車のうち 1 台が加速し、被験者が先行車両を追い抜くことができるように道を開けた。図 4(b) に示すように Lead が加速した場合、被験者は車線変更を行い、Preceding を追い抜く。図 4(c) のように Preceding が加速した場合、被験者は現在の車線を維持しながら加速し、Lead を追い抜く。

最初に被験者は特定の運転行動を指示されず、上記のタスクを 20 回行った。20 回の計測のうち、Preceding が加速するケースが 10 回、Lead が加速するケースが 10 回、順番はランダムとした。20 回の計測後、被験者に「慎重に運転してください」と運転行動を指示し、同様に 20 回の計測を行った。最後に「急いで運転してください」と運転行動を指示し、20 回の計測を行った。以上のように「平常」、「慎重」、「急ぎ」の 3 つの運転行動ごとに 20 回の計測を行い、指定




Fig. 5 Repulsive Energy under Each Driving Behavior

された運転行動による挙動の違いを解析した。

本研究では、先行車に追従する際の車両挙動から運転行動を推定することが目的であるため、計測開始直後の先行車に近づくまでのデータや先行車を追い抜く際のデータは除外し、追従時における取得データのみを識別モデルの学習および評価に用いた。

Table 1 Average Repulsive Energies

Driving Behavior	Cautious	Normal	Hurry
Repulsive Energy	0.20J	0.29J	0.44J

3.2 推定性能の評価

各運転行動における Preceding からの斥力ポテンシャルエネルギーを図 5 に示す。この結果は 20 回の計測のうち 1 回分の結果である。緑色の線が「慎重」における斥力ポテンシャルエネルギーを、黄色い線が「平常」における斥力ポテンシャルエネルギーを、赤い線が「急ぎ」における斥力ポテンシャルエネルギーを表す。エネルギーの変化が激しいほど、車間距離や相対速度が激しく変化することを表し、より手荒く運転したことを意味する。

図 5 から「急ぎ」条件におけるエネルギーが激しく変化したことが確認できる。これに対し、「慎重」と「平常」におけるエネルギーは徐々に変化した様子である。各運転行動条件における 20 回の計測結果を平均し、比較した結果を表 1 に示す。この結果から危険度の高い運転行動を取るほど、高いエネ




Fig. 6 Accuracy under Each Driving Behavior by Estimation Methods




Fig. 7 Accuracy under Each Driving Behavior by Filtering Methods

Table 2 Accuracy Comparison by Filtering Methods

	None	Bayesian	Proposed
Accuracy	66.6%	66.2%	69.0%

ルギーが得られることが確認できる。各条件における平均値の差が大きくなるほど、特徴量として有効であり、推定性能を向上させることができる。そのためには、斥力ポテンシャルエネルギーを算出する際のパラメータを適切に調整する必要があるが、その方法はまだ提案されていない。このパラメータの最適化は今後の課題である。

提案手法の有効性を評価するため、先行車追従時における車両挙動から推定した運転行動の推定精度を基礎モデルおよび従来手法と比較した。その結果を図 6 に示す。基礎モデルは特徴量として先行車との車間距離、相対速度の 2 つを使用したものであり、識別手法は SVM を用いた。従来手法としては、先行車との車間距離、相対速度、リスク認知指標の 3 つを特徴量とする三上らの手法を実装した (4)。基礎モデルおよび従来手法の推定精度は提案手法と同様の評価データを用いて算出したものである。この結果から提案手法を用いることで、従来手法より優れた推定精度が得られることを確認した。すなわち、先行車からの斥力ポテンシャルエネルギーは特徴




Fig. 8 Estimated Driving Behavior

Table 3 Performance Comparison

	Basic	Mikami ⁽⁴⁾	Proposed
Accuracy	65.2%	65.1%	69.0%

量として有効であり、各運転行動における車両挙動を適切に記述することが可能であると考えられる。

SVM の識別結果をそのまま用いた際の推定精度とベイズアンフィルタを適用した際の推定精度、提案フィルタリング手法を適用した際の推定精度を比較した。その結果を図 7 および表 2 に示す。SVM の出力をそのまま用いた結果に対し、ベイズアンフィルタを適用することで「平常」および「急ぎ」条件における推定精度が向上した。しかし、「慎重」条件における推定精度が低下することを確認した。この結果に対し、過去の推定パターンを考慮した補正を行うことで、すべての運転行動における推定精度を向上させることが可能であった。1 回の計測データにおける時系列の推定結果を図 8 に示す。グラフの縦軸は推定された運転行動を表しており、1 が「慎重」を、2 が「平常」を、3 が「急ぎ」を意味する。図 8 のグラフは「慎重」の運転行動を指定した際の結果であり、真値は 1 である。すなわち、推定結果が 1 を保つほど正しい推定が行われたことを意味し、推定結果が 2 や 3 となるのは誤推定となる。緑色の線が SVM の出力をそのまま使用した結果を表し、赤い線が提案フィルタを適用した結果である。提案フィルタを適用することで、誤推定の発生を抑えられることが確認できる。

最終的に新規特徴量および過去の推定パターンを考慮した推定精度の補正を行った提案手法の性能を評価するため、基礎モデルおよび従来手法との推定精度比較を行った。その結果を表 3 に示す。提案手法の推定精度は 69.0% であり、基礎モデルおよび従来手法を上回る精度を達成した。以上の結果から提案手法の有効性が示された。

3.3 考察

基礎モデルと従来手法の推定精度を比較した結果から特徴量を追加することが必ずしも識別性能の向上につな

Table 4 Number of Estimated Driving Behavior

		Estimation Result		
		Cautious	Normal	Hurry
Ground Truth	Cautious	30238	12420	1275
	Normal	16482	17036	10229
	Hurry	882	3273	39815

がるとは限らないと考えられる。従来手法はリスク認知指標という特徴量を提案し、先行車との車間距離、相対速度から抽出を行った。しかし、表3から確認できるように推定精度が低下する結果となった。すなわち、適切ではない特徴量の追加は推定性能低下の原因となり得るという知見が得られた。これに対し、本研究で提案する斥力ポテンシャルエネルギーを特徴量として追加した場合、全運転行動条件において推定精度が向上した。この結果から提案特徴量は運転行動を適切に記述することが可能な特徴量であると言える。

運転行動ごとに結果を比較すると、「慎重」および「急ぎ」と比べて「平常」の推定精度が極めて低いことが確認された。このような結果となった原因としては2つが考えられる。1つ目は計測を行う前に運転行動を明示的に指定しなかったため、実際に「慎重」や「急ぎ」の運転行動を取ったと考えられる。被験者は何も意識することなく運転を行ったため、普段の運転スタイルやそのときの心理状態によって「慎重」や「急ぎ」のどちらかに偏った運転行動を見せたと考えられる。表4に全評価データにおける提案手法より推定された結果のデータ数を示す。真値が「平常」の場合における推定結果をみると、提案手法より「慎重」であると推定された結果データ数が多いことが確認できる。また、真値が「慎重」の場合における推定結果が「急ぎ」より「平常」であると推定されたデータ数が多くなっている。この結果から被験者が基本的に「慎重」な運転スタイルや心理状況であったと考えられる。この仮説を検証するためには、多数の被験者による実験を行い、運転者個人の特性がどのように影響するのかを分析する必要がある。

「平常」に対する推定精度が低くなった2つ目の原因としては、手法自体に問題がある可能性も否定できない。今回構築した識別モデルは多数のパラメータにより設定された。SVMはカーネルの選択によって識別性能が大きく左右される。また、radial basis functionにおけるパラメータも最適化された値ではなく、経験によって設定されたものである。そのため、識別モデルを最適化することで、より優れた推定性能が得られる可能性は十分にあると考えられる。様々なパラメータ設定による性能評価も重要な検討事項である。

4. 結論

本研究では、先行車追従時における車両挙動から運転者

の運転行動を推定する手法の構築を行った。動特性ポテンシャル法を用いた運転の危険度を表す特徴量を新規に提案し、先行車との車間距離および相対速度を適切に考慮することができる連続的な値を抽出した。また、過去の推定パターンを考慮した推定精度の補正を行うことで、推定性能の向上を試みた。DS実験による提案手法の有効性を評価した結果、従来手法より優れた推定精度を達成した。

今後の課題としては、「平常」の運転行動に対する推定精度低下の原因を解明するため、多数の被験者によるDS実験データを解析する必要がある。また、推定手法の最適化に関する検討も要求される。

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, U.S. DOT, Washington, DC, USA, Rep. DOT HS 808 075 (1994)
- (3) H. Woo, Y. Ji, H. Kono, Y. Tamura, Y. Kuroda, T. Sugano, Y. Yamamoto, A. Yamashita, and H. Asama : Lane-change detection based on vehicle-trajectory prediction, IEEE Robotics and Automation Letters, Vol. 2, No. 2, p. 1109-1116 (2017)
- (4) 三上晃司, 奥田裕之, 鈴木達也, 田崎勇一, 伊佐治和美, 津留直彦 : ハイブリッドシステム論による前方車追従行動におけるモデル予測型アシスト制御の実現, 計測自動制御学会産業論文集, Vol. 9, No. 5, p. 29-36 (2010)
- (5) D. Filev, J. Lu, F. Tseng, and K. Prakah-Asante, Real-time driver characterization during car following using stochastic evolving models, Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics, p. 1031-1036 (2011)
- (6) H. Woo, Y. Ji, H. Kono, Y. Tamura, Y. Kuroda, T. Sugano, Y. Yamamoto, A. Yamashita, and H. Asama : Automatic detection method of lane-changing intentions based on relationship with adjacent vehicles using artificial potential fields, International Journal of Automotive Engineering, Vol. 7, No. 4, p. 127-134 (2016)
- (7) 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, Proceedings of the IEEE International Conference on Robotics and Automation, p. 2347-2354 (2015)
- (8) K. P. Bennett and E. J. Bredensteiner : Duality and geometry in SVM classifiers, Proceedings of the IEEE International Conference on Machine Learning, p. 57-64 (2000)
- (9) P. Kumar, M. Perrollaz, S. Lefevre, and C. Laugier : Learning-based approach for online lane change intention prediction, Proceedings of the IEEE International Conference on Intelligent Vehicle Symposium, p. 797-802 (2013)