ハイブリッドシステムモデルに基づく運転行動解析*

—データクラスタリング手法からのアプローチ—

山田晋**, 鈴木達也**, 稲垣伸吉**, 早川聡一郎***, 土田縫夫***, 津田太司****, 藤波宏明****

This paper presents a new analysis technique of the human driving behavior based on expression as the Piece Wise Linear (PWL) model together with application to driver's collision avoidance behavior. The driving data were collected by using the three-dimensional driving simulator based on CAVE, which provides stereoscopic immersive vision. The identification problem for the PWL model was solved by combining the Data Clustering technique and the Support Vector Machine. From the obtained results, it became possible to capture not only the physical meaning of the driving skill, but also the decision-making aspect (switching conditions) in the driver's collision avoidance behavior.

本論文では前方車両回避運動を対象とし、PWLモデルに基づきドライバーの運転行動のモデル化を行った。走行データは、3次元没入型VR装置であるCAVEを用いたドライビングシミュレータにより収集した。データクラスタリング手法とサポートベクターマシンを組み合わせ、PWL形式として運転行動を表現することで、前方車両回避時における運転行動の動作と判断の両側面の推定を行った。
(キーワード：ハイブリッドシステム、Piece Wise Linear モデル、システム同定、前方車両回避)

1. はじめに

ドライバーの運転行動を解析、モデル化し、それに基づいて適切に運転行動を予測、アシストする技術の開発は、安全な自動車操作システムの設計における最重要課題とみなすことができよう。運転行動を理解するため様々なアプローチが行われているが^{1) 2) 3) 4) 5)}、ドライバの運転特性を定量的にモデル化し評価する手法は数少ないのが現状である。そのような中で運転行動をモデル化する手法として、運転行動を知覚情報からハンドルやアクセルの操作へのマッピングとして定義し、(1)線形の伝達関数として表現するモデル⁶⁾、(2)ニューラルネットワーク等の非線形動特性を内包した動的システムモデル⁷⁾、さらには(3)抽象化したシステムモデル(オートマトンやif-then形式のルール等)に立脚したモデル、等の数理モデルがこれまで提案されてきた。(1)(2)は連続時間系の

記述モデルであり、(3)は離散事象系の記述モデルとみなすことができる。人間の行動が複雑で多様であることを考えると、(1)や(3)はその記述能力という点において疑問が残る。一方、アシスト系の設計等の工学的利用の観点からすると、(2)で得られたモデルは、その複雑さゆえに、有用性に大きな疑問を感じる。

本論文では、「人間が見せる複雑な行動は、一連のプリミティブな動作モードとその切り替えによって実現される」との考え方に立って、運転行動の数理モデル化を試みる。具体的には、モードの切り替えが離散事象的な機能であるのに対し、各動作モードが連続時間系の動的な機能として捉えられることに着目し、ハイブリッドダイナミカルシステム(HDS)の考え方^{8) 9)}に基づいた新しいシステムモデルを導入することで、新たな行動のモデル化手法の構築を目指す。ここで得られる行動モデルは、一見すると複雑に見える行動を、いくつかの動作モードの集合とその切り替えで表現することにより、(1)物理的理解が容易、(2)計算コストが少ない、(3)表現能力が高い、モデルとなっている。結果として、行動の実時間予測やアシスト系の設計等の工学的利用につなげやすいモデルであるという特長を有する。また、提案モデルで現れる動作モードの切り替え条件は、人間の脳内情報処理

*受付：2005年8月3日 受理：2006年5月2日

**名古屋大学

Nagoya University

***豊田工業大学

Toyota Technological Institute

****トヨタ自動車

Toyota Motor Corporation

図 1 (a) CAVESystem. (b) DS の構成。
Fig. 1 (a) CAVESystem. (b) Configuration of driving simulator.

における上位プロセスでの判断に相当するとも考えられ、観測した操作データに基づいたその明示的抽出、モデル化が本提案手法の大きな特徴となっている。

一方、HDS に関する研究は、ここ数年、検証や制御、安定解析、記述方法など、多くの文献で取りあげられているが¹⁰⁾、人間の行動解析に適用された例はほとんど無い。本論文では、確定的な HDS モデルに対する、データクラスタリングとサポートベクタマシンに基づいたパラメータ推定法を導入し、ドライバの前方車回避行動の解析に応用した結果を示す。より具体的には、前方車が急停止した場合におけるドライバの危険回避行動を差分方程式と論理が混在した HDS の一種である区分線形モデル (PWL モデル) を用いて表現する。この場合、各モードにおける数理モデル (上述の動作モードに相当) は単純な線形のモデルで表現されることになる。そして PWL モデルのパラメータ推定問題をデータクラスタリング¹¹⁾を用いて一連の運転行動をいくつかの動作モードに分解するフェーズと、サポートベクタマシンを用いて各モード間の分離面 (切り替え条件) を求めるフェーズとに分けて解く。

2. ドライビングシミュレータの構成

Fig.1 (a),(b) に本研究で用いたドライビングシミュレータ (以下 DS) の外観とその構成図を示す。構築した DS は没入型の三次元立体視情報を提示可能な CAVE を表示部分に用いており、表示部の制御は ONYX2で行っている。また、CAVE 内にハンドル、アクセル、ブレーキを持ち込み、仮想コックピット環境を構築した。表示用プログラムの開発には CAVE ライブラリおよび Performer を用いた。

本 DS の特徴は、被験者の視点位置と視線方向を検出しているため、それらに基づきリアルタイムに表示を更新することで、高い没入感を得ることができる点である。また 2 次元表示型の DS と比べ、より正確な距離感を得

られることがあげられる¹²⁾。

3. 仮想環境と想定タスク

本研究では、被験者が脇見している間に前方車が急停止した場合の回避行動に限定して、道路環境ならびに運転条件を設定した。Fig.2 に走行環境の一例を示す。

本実験の前に予備実験を行い、前方車を回避する際にとっさに行動しないと回避しきれないような余裕のない状況ではなく、ある程度ドライバの判断が入る余地のあるように車間距離を設定した。本研究ではドライバの回避行動をモデル化するために、ドライバの知覚情報 (入力) として自動車の

- 前後車間距離 x_1
- 前後相対速度 x_2
- 左右相対位置 x_3

を計測し (Fig.3 参照)、またドライバの操作量 (出力) としては

- ステアリング操作量 y

を用いた。入力にこの三つの情報を選んだ理由としては、(1) 筆者らの従来研究において、ドライバの回避行動においてはこれら三つが最も本質的な知覚情報であることが報告されていること¹³⁾、(2) 直感的に考えてもこの 3 種類の情報を用いることでドライバーは自車と前方車の幾何学的位置関係を把握できると考えられること、(3) この 3 種類の情報は現存するセンサで獲得が可能であること、の 3 点が挙げられる。なお、本研究の運転条件では前方車を回避するのに十分な車間距離があり、ブレーキを使用せずとも回避が可能であるということから、またブレーキを使用して回避を行う被験者が少なかったということから、出力としてステアリング操作量のみを考える。本研究で

図 2 走行環境
Fig. 2 Driving environment

用いた道路環境は住宅地であり、交差点を含む直線道路で構成されている。全長 1[km] の一方通行となっており、この直線道路を繰り返し走行する。天候はくもりで暑い

図 3 入力情報
Fig. 3 Input information

た路面を想定し、摩擦係数は現実とほぼ同じく 0.8 とした。全部で 6 カ所の信号交差点があるが、進行方向の信号が常に青であり、赤に変わることはない。環境内を走行している車両は自車と前方車（大型トラック）のみであり、被験者には 50[km/h] (13.9[m/s]) で走行している前方車をオペレータが設定した前後車間距離 (21[m]) をおおよそ保ちながら追走してもらった。交差点に差し掛かったところで被験者に右を向いてもらい、駐車車両の色を答えてもらう。そして被験者が右を向くのと同期し、ランダムで前方車を急停止させ、その際の被験者の回避行動、その後の復帰行動における走行データを計測する。

4. 運転行動のモデル化

4-1. PWL モデルとしての表現

ドライバは走行中に何度か「判断」を行い、複数の「動作」を組み合わせ、前方車を回避していると考えられる。そこで、回避行動における入出力関係をいくつかの「動作」とその「切り替え条件（判断）」とからなる PWL モデルを用いて表現する。本研究ではデータ解析区間を、被験者が前方車を回避するためハンドルを切り、通常走行に戻るためハンドルを戻すまでの区間とした。この間のステアリングの動きは、前方車を回避するため「右に切り」、車体を安定させるとともに前方車を追い越すため「左に戻し」、元の車線に復帰するために再度「右に切る」という 3 つのモードからなっていると考えられる^(注1)。そこで前方車が急停止した際の回避行動を 3 つの「動作」モードからなるものと考え、「回避」「追い越し」「復帰」というラベルをつけることとする。ただし、ここでつけたラベルは比較的多く見られる回避行動を想定して便宜上つけたものであり、5-2 節で述べるように、必ずしもすべての回避行動がこのラベル付けで説明可能になるとは限らない。

今、次式に示すような PWL モデルを用いてドライバの運転行動をモデル化する。

(注1) ハンドルの切り角を、右方向を正の角度として表現するとき、切り角の微分値が正（負）の状態を「右（左）に切る」と呼ぶことにする。

mode A（回避）

$$y_{k+1} = a_1 x_{1,k} + a_2 x_{2,k} + a_3 x_{3,k} \text{ if } \mathbf{x}_k \in C_1 (1)$$

mode B（追い越し）

$$y_{k+1} = b_1 x_{1,k} + b_2 x_{2,k} + b_3 x_{3,k} \text{ if } \mathbf{x}_k \in C_2 (2)$$

mode C（復帰）

$$y_{k+1} = c_1 x_{1,k} + c_2 x_{2,k} + c_3 x_{3,k} \text{ if } \mathbf{x}_k \in C_3 (3)$$

ここで $x_{1,k}, x_{2,k}, x_{3,k}, y_k$ は、それぞれ前後車間距離、前後相対速度、左右相対位置、ステアリング操作量を表し、 $\mathbf{x}_k$ は入力ベクトル $(x_{1,k}, x_{2,k}, x_{3,k})$ を、 C_1, C_2, C_3 はそれぞれ各モードに該当するデータ空間の部分集合を示す。 k は時系列データの番号である。上式において、 $a_i, b_i, c_i (i = 1, 2, 3)$ は未知パラメータであり、また、 C_1, C_2, C_3 の領域の境界も未知である。このように C_1, C_2, C_3 の境界が未知である点が、通常の線形系に対するパラメータ推定問題と大きく異なっている点である。

上記のように運転行動を表現することで、動作系（パラメータ $a_i, b_i, c_i (i = 1, 2, 3)$ により表現）と判断条件（ C_1, C_2, C_3 の境界面により表現）の混在する系としての解析が可能となる。

以下では解析区間における観測データ $x_{i,k}, y_k$ に対し、最も精度良く再現できるパラメータを求める問題を考える。

4-2. クラスタリングによるモード分割

図 4 クラスタリングの概略
Fig. 4 Outline of clustering

本研究では観測データは単位がそれぞれ異なっており、どの入力（知覚）情報を重視しているかを調べるという観点から、各データに対し、(4) 式のように正規化を行う。

$$\bar{x}_i = \frac{x_i}{\max |x_i|} \quad (4)$$

次に本研究で用いたクラスタリング手法⁽¹¹⁾の概略を以下に示す。

1. データ系列 P が得られた場合、Fig.4(a) のように各 $P_i (i = 1, 2, \dots, n)$ に対し距離の近い c 個のデータを集め局所集合 LDs_i を作り、特徴量 ξ_i を得る。

ここで特徴量 ξ_i は、 LDs_i 中のデータに対して (1)~(3) 式と同じ数理構造を持った線形モデルを想定し、最小二乗推定を施すことにより得られるパラメータと、 LDs_i 中のデータの平均値から構成される。

2. データ系列 P 中の各データ $P_i (i = 1, 2, \dots, n)$ を特徴量 ξ_i に変換することで特徴空間における分布を得る (b). そして、特徴空間上のデータに対し、K-means 法に基づいてクラスタリングを行う (c).
3. 特徴空間におけるクラスタリング結果を元のデータ系列 P に割り当て (d), 各「動作」に対応させる。
4. クラスタリングされたデータ系列 P 中の各モードに対し、最小二乗推定を施すことで各モードにおけるパラメータ、 $a_i, b_i, c_i (i = 1, 2, 3)$ を求める。

一般には3章で定義した入力情報を変えた場合、モード分割結果が変わる可能性があると考えられる。しかしながら、ここでは観測変数そのものではなく、観測変数から得られる局所ダイナミクスの係数を特徴量 ξ_i に含めてクラスタリングを行っていることから、より観測変数に依存しない形でダイナミクスの変化を捉える、すなわちモード分割が可能となると期待できる。

4-3. サポートベクターマシン (SVM) による境界の推定

区分化された「動作」を切り替える際、ドライバーは何かしら「判断」を行っていると考えられる。前節でクラスタリングされた各モードをそれぞれの「動作」とみなす場合、モード間の境界、つまり「動作」を切り替える条件は、「動作」を切り替える際に用いた判断条件を表していると考えられる。本研究では切り替え条件を簡略に表現するため、非線形式としての識別関数 (各モード間の境界) は考えず、線形式としての識別関数を用いることとし、 C_1, C_2, C_3 の境界面を求めることにした。以下に線形 SVM の概要を示す。

SVM は基本的に2クラスの識別器を構成するための学習法である。今、学習データを $\mathbf{x}_i$ 、クラスラベルを $t_i \in \{-1, 1\}$ としたとき、もし学習データが線形分離可能であれば次式を満たす識別関数のパラメータ $\{\mathbf{w}, h\}$ が存在する。

$$\begin{aligned} \mathbf{w}^T \mathbf{x}_i - h &\geq 1 \text{ if } t_i = 1 \\ \mathbf{w}^T \mathbf{x}_i - h &\leq -1 \text{ if } t_i = -1 \end{aligned} \quad (5)$$

SVM は2枚の超平面 $\mathbf{w}^T \mathbf{x}_i - h = 1$ と $\mathbf{w}^T \mathbf{x}_i - h = -1$

との間の距離 $1/\|\mathbf{w}\|$ が最大となるような識別関数を求める手法 (マージン最大化) であるが、これは、上式を制約条件とした以下のような2次計画問題として定式化することができる。

$$\begin{aligned} \min \quad & L(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 \\ \text{subject to} \quad & t_i(\mathbf{w}^T \mathbf{x}_i - h) \geq 1, \quad i = 1, \dots, N \end{aligned} \quad (6)$$

さらに2つのクラスが線形識別可能でない場合は、非負の変数 τ_i を導入して、二次計画問題を以下のように定式化し直せばよい。

$$\begin{aligned} \min \quad & L(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 + \mu \sum_{i=1}^N \tau_i \\ \text{s.t.} \quad & t_i(\mathbf{w}^T \mathbf{x}_i - h) \geq 1 - \tau_i, \\ & \tau_i \geq 0, \quad i = 1, \dots, N \end{aligned} \quad (7)$$

ここで τ_i は超平面からの逸脱量を示し、 μ はその重み係数である。このようにして、制約を緩めることで多少の識別誤りを許す手法を「ソフトマージン法」と呼び、本研究でもこの定式化に基づいて判断条件、すなわち、 C_1, C_2, C_3 の境界面を求めた。

5. 回避行動のモデル化および解析結果

5-1. 対象とした被験者

本研究では20代男性3名の走行データについて解析を行った。被験者Aは回避時にブレーキをほとんど使わないという特徴を有しており、1セット10回の走行実験を時間をあけて計4セット行った。被験者Bは比較的ブレーキを使うという特徴を有しており、2セットの走行実験を行った。被験者Cは被験者A同様に、ブレーキを余り使用せず回避を行っており、2セットの走行実験を行った。

5-2. モード分割と各動作モードにおけるパラメータの同定

解析に用いた走行データのクラスタリング結果の例をFig.5~Fig.12に示す。各セットで前方車の回避に失敗したデータを除き、3回分の走行実験データを用いてクラスタリングを行った結果である。

横軸は車間距離 [m]、縦軸は上から順にステアリング操作量 [degree]、左右相対位置 [m]、前後相対速度 [m/s] である。またハンドルを右に回した場合を正、左に回した場合を負とし、左右相対位置は前方車に対し右を正、左を負とする。前後相対速度は自転車速度と前方車速度の差

図 5 被験者 A—Trial 1
Fig. 5 Subject A—Trial 1

図 8 被験者 A—Trial 4
Fig. 8 Subject A—Trial 4

図 6 被験者 A—Trial 2
Fig. 6 Subject A—Trial 2

図 9 被験者 B—Trial 1
Fig. 9 Subject B—Trial 1

図 7 被験者 A—Trial 3
Fig. 7 Subject A—Trial 3

図 10 被験者 B—Trial 2
Fig. 10 Subject B—Trial 2

である。データのサンプリング周期は 0.096[sec]とした。

Tab.1 に各モードでのパラメータ同定の結果と、モデルの当てはまりの指標として各モードに対する自由度調

整済み重相関係数¹⁴⁾(R_A, R_B, R_C)を示す。これは 1 に近いほどモデルの精度が良いことを表す指標である。被験者 A の 3 回目及び 4 回目の実験の R_A は他と比べ低く

図 11 被験者 C—Trial 1
Fig. 11 Subject C—Trial 1

図 12 被験者 C—Trial 2
Fig. 12 Subject C—Trial 2

なっているが、他の実験については R_A, R_B, R_C の値が十分に 1 に近く、精度良くモデル化されていることが分かる。

次に各モードの特徴について述べる。まず mode A (回避モード) では、前後車間距離に対するゲイン (a_1) の符号が負、前後相対速度に対するゲイン (a_2) の符号が正、となっている。また、左右相対位置に対するゲイン (a_3) の符号は概ね負となっている。また、被験者 A 及び C は左右相対位置に対するゲイン a_3 の大きさが大きい傾向にあるのに対し、被験者 B は 3 つの知覚情報の中で相対速度に対するゲイン (a_2) の大きさが最も大きい傾向にある。このことは mode A においては、被験者 A, C は左右相対位置を比較的重視してステアリング操作を行っているのに対し、被験者 B は相対速度を重視してステアリング操作をしていることを意味している。この点はブレーキ操作の有無とも関係していると考えられ興味深い。また、被験者 A の 3, 4 回目と被験者 C の 2 回目は右にス

テアリングを切り、次いで左に切る部分を含めて mode A となっているのに対し、他の実験では右に切り終えるまでが mode A となっている。mode B 以降のステアリングの動きと合わせて考えると、前者の場合は mode B 以降におけるステアリングの切り角が後者に比べ小さく、滑らかにステアリング操作を行っていることが見て取れる。つまり、前者は前方車を回避した後の操作まで意識して回避動作を行っているのに対し、後者は前方車を回避することのみを重視した回避動作を行っていると考えられる。

表 1 PWL モデルのパラメータ同定結果

Tab. 1 Identified parameters in PWL model

	A-1	A-2	A-3	A-4
a_1	-0.550	-0.763	-0.695	-0.918
a_2	1.604	1.873	1.791	1.767
a_3	0.743	-1.000	-3.302	-3.705
R_A	0.978	0.964	0.877	0.878
b_1	3.012	1.077	-0.288	-1.088
b_2	-1.140	-0.482	-0.790	0.689
b_3	-0.367	-0.805	0.344	-1.139
R_B	0.971	0.921	0.978	0.962
c_1	-1.366	-1.153	0.024	-0.078
c_2	-0.840	-0.720	0.523	0.562
c_3	0.100	0.028	-0.865	-1.003
R_C	0.979	0.965	0.992	0.986

	B-1	B-2	C-1	C-2
a_1	-0.534	-1.122	-0.708	-0.687
a_2	1.294	2.314	1.657	1.892
a_3	0.905	-0.335	-2.499	-3.017
R_A	0.993	0.981	0.929	0.925
b_1	2.289	2.143	1.778	-0.910
b_2	-0.701	-0.886	-0.949	1.018
b_3	0.807	-0.780	-0.358	-2.063
R_B	0.989	0.980	0.972	0.989
c_1	-1.679	-0.408	-1.821	-0.376
c_2	-0.453	-0.349	-0.645	1.162
c_3	-1.360	-0.540	-0.169	-2.101
R_C	0.994	0.990	0.981	0.999

また mode B では、前後車間距離に対するゲイン (b_1) の大きさが大きくなる傾向にあり、mode A との比較で考えると、より車間距離を重視した動作則に移行していると考えられる。

最後に、mode C では、同じ被験者でも異なった動作パターンを見ることができる。これは、前方車を回避後、被験者にとって明確なターゲットが存在しないこと、また、「すみやかに元の車線に戻るように」等の具体的な指示を与えなかった等の理由から、車線の戻り方にばらつきが生じ、解析結果にも同様にばらつきが観測されたと考えられる。

本節では、各モードの意味について、得られたパラメータをもとにその解釈を与えることを試みた。しかしながら、被験者 A の 3,4 回目のデータに見られるように、4-1 節で述べた各モードのラベル付けは必ずしも当てはまらない場合が生じてくる。このような各モードにおける行動の多様性は、あらかじめ規定するモードの数とも密接な関係があると考えられる。本研究では一様にモードの数を 3 としたが、このモードの数についても本来は個人差があると考えられる。一様に 3 としたのは、モード数未知のクラスタリング問題がそれほど容易な問題ではないこと、また、これまでの経験上、「回避」「追い越し」「復帰」というモード分けは定性的には自然と考えられること、が理由であった。モードの数をいろいろと変えて同様のモデル化手法を適用すると、また異なったラベル付けが必要になると考えられる。例えば、被験者 A の 3,4 回目のデータに対して、モード数を 4 としてモデル化を行うと、最初のモードが 2 つに分かれる可能性がある。このことは、Tab.1 において、被験者 A の 3,4 回目のデータに対する mode A での重相関係数 R_A が他と比べて低い値となっていることから推測される（つまりさらなる分割が必要であることを暗に示していると考えられる）。このように、各モードに割り付けるラベルはモード数によっても変わる可能性があり、その意味では、何らかの規範の基に最適なモード数を見つける問題をクリアしないと意味ラベルの妥当性に関する議論は困難であろう。この点については、モード数未知の場合にも適用可能なクラスタリング手法を導入することで可能となるが、本論文ではこれ以上は触れず、稿を改めて論じる予定である。

5-3. モードの切り替え条件の同定結果

モード間の切り替え条件を表す分離面のパラメータの同定結果を Tab.2 に示す（表中の mode A $\rightarrow$ B は mode A, B 間の、mode B $\rightarrow$ C は mode B, C 間の分離面を示す）。ここで、分離面の線形式は式 (8) とした。

$$\alpha x_1 + \beta x_2 + \gamma x_3 = h \quad (8)$$

C-1 の走行データを例にとり Fig.13 に分離面を示す。Fig.13 中の x_1, x_2, x_3 は正規化した値となっている。

ここで得られた分離面に関しては、残念ながらその精度を定量的に評価することは困難であると考えられる。なぜならば、分離面を観測することはできないため、正しい分離面がわからないからである。ただ、一般に SVM はモード間のオーバーラップが少ないほどより適切な分離面が推定できるアルゴリズムであり、5-2 節のモード

表 2 分離面のパラメータ同定結果
Tab. 2 Identified parameters in Hyperplane

mode A $\rightarrow$ B	α	β	γ	h
A-1	1.000	-1.297	-1.277	-0.500
A-2	1.000	-0.832	-1.002	-0.123
A-3	1.000	-0.451	-1.415	-0.723
A-4	1.000	-0.709	-1.146	-0.587
B-1	1.000	-0.059	-1.242	0.472
B-2	1.000	-0.235	-0.935	0.596
C-1	1.000	-0.388	-1.366	-0.473
C-2	1.000	-0.644	-1.462	-0.648
mode B $\rightarrow$ C	α	β	γ	h
A-1	1.000	-0.005	-0.801	-0.585
A-2	1.000	-0.081	-0.809	-0.622
A-3	1.000	-0.152	-0.073	-0.408
A-4	1.000	-0.127	-0.487	-0.650
B-1	1.000	0.168	-0.576	-0.080
B-2	1.000	-0.027	-1.219	-0.688
C-1	1.000	0.109	-0.585	-0.264
C-2	1.000	-0.004	-0.309	-0.379

分割結果を見ると、比較的モード間のオーバーラップが少ない分割ができているため、本研究において SVM により推定された分離面は、モード間の分離面として信頼性が高いものであると考えられる。

得られた分離面をより直感的に理解するため、 $x_1 - x_3$ 軸上にプロットした図を Fig.14 に示す。なお Fig.14 に表示された分離面は、モードが切り替わる時の相対速度 $x_2^{(注2)}$ を式 (8) に代入し描いたものである。また Collision Area に自転車（運転席の位置）が入り込むと、自転車と前方車の衝突が起こることを意味する。Fig.14 を見ると、左右相対位置が大きいほど次のモードへと早く移行することが、分離面から理解できる。

次に分離面を表すパラメータをより詳細に検討する。全被験者の mode A（回避モード）から mode B（追い越しモード）への切り替え条件式においては車間距離と左右相対位置の符号（ α と γ の符号）が逆であり、左右相対位置が大きいほど早く「追い越し」に動作モードを切り替えていると考えられる（Fig.14 参照）。また、 α と β の符号関係に関してもほぼ同様な傾向が見られるが、これは相対速度が大きいほど早めにモードの切り替えが起こること、つまり Fig.14 において、分離面を表す青い線のうち左側の線（mode A から mode B への移行をある一定の相対速度下で描いた線）が相対速度が速い場合に左へ移動することを表しており、自然であると言えよう。

また、被験者 B は β の大きさは他の被験者に比べ小さ

(注2) 厳密には、mode A $\rightarrow$ B 間の分離面に最も近い観測データを mode A, B から選び、その相対速度の平均を用いた。mode B $\rightarrow$ C 間の分離面についても同様。

い。これは、被験者 B が「追い越し」に動作モードを変化させる際の判断基準として相対速度の情報をあまり重視していないためと考えられる。次に mode B（追い越しモード）から mode C（復帰モード）への切り替え条件式においては、相対速度の係数 β は小さく車間距離と左右相対位置の係数 α と γ は大きい。このことは、前方車を追い越す動作から、元の走行車線に戻る動作への切り替えは、車間距離と左右相対位置に基づいて判断がなされていると考えられる。

図 13 C-1 における分離面

Fig. 13 Hyperplane obtained from C-1

図 14 C-1 における車両の位置関係とモードの対応

Fig. 14 Relationship between vehicle and modes for C-1

6. まとめ

本論文ではドライバーの危険回避行動をハイブリッドシステム表現に基づいた動作・判断混在型の行動として理解するための新しい枠組みを提案した。具体的には、ドライバーの危険回避行動をモデル化するために、前後相対位置、前後相対速度、左右相対位置を入力、ステアリング操作量を出力とする切り替え型のコントローラモデルを考え、このモデルを論理判断の伴う区分線形モデル

を用いて表現した。そして、各区分線形モデル中のパラメータをデータクラスタリングによって、また、切り替え条件式をサポートベクタマシンを用いて同定した。得られた結果は興味深く、今後、動作と判断の混在した他の様々な行動解析への適用が期待されるが、その一方で、各モードに割り付けるラベルについては、モード数の選定とも密接な関係があると考えられ、厳密な意味づけができていないと言え難い。モード数の最適化を含めた行動解析手法の確立および他のモデル化手法との定量的な比較が今後の重要な課題として挙げられる。

謝 辞

本研究は豊田工業大学宇宙ロボティクス研究センターに設置されている CAVE を用いて行われました。宇宙ロボティクス研究センターの関係者各位に感謝申し上げます。

参考文献

- 1) 澤田東一, 小口泰平: 車間距離制御における運転者の動作特性, 人間工学, 33(6), 363~370, 1997
- 2) 宇野 宏, 平松金雄: 緊急状況における余裕時間とドライバの操舵回避との関係, 人間工学, 35(4), 219~227, 1999
- 3) 土井俊一: ドライバの運転特性評価の現状と将来, 自動車技術, 58(12), 4~9, 2004
- 4) 特集号: ドライバの運転特性と評価, 自動車技術, 58(12), 2004
- 5) 大日方五郎: 高齢者運転適正ハンドブック, 自動車技術会編, 2005
- 6) T. Pilutti and A.G. Ulsoy: Identification of Driver State for Lane-Keeping Tasks, IEEE Trans. on Syst. Man and Cyber., Part A, 29(5), 486~502, 1999
- 7) K.S. Narendra and K. Pathasaraty: Identification and Control of Dynamical Systems Using Neural Networks, IEEE Trans. on Neural Networks, 1(1), 4~27, 1990
- 8) R. Alur and G.J. Pappas: Hybrid Systems: Computation and Control, Lecture Notes in Computer Science (LNCS) 2993, Springer Verlag, 2004
- 9) M. Morari and L. Thiele: Hybrid Systems: Computation and Control, Lecture Notes in Computer Science (LNCS) 3414, Springer Verlag, 2005
- 10) A. Bemporad and M. Morari: Control of Systems integration logic, dynamics, and constraints, Automatica, 35(3) 407~427, 1999
- 11) Giancarlo Ferrari-Trecate et al., A clustering technique for the identification of piecewise affine system, Automatica, 39(2), 205~217, 2003
- 12) J.H. Kim, Y. Matsui and S. Hayakawa et al.: Acquisition and Modeling of Driving skill using Three-

Dimensional Virtual System, Proc. of ICASE/SICE
Joint Workshop, Vol.1, 49~53, 2002

- 13) M.Koashi, S.Hayakawa et al.: Measurement and
Modeling of Collision Avoidance Behavior of Drivers

Using Three Dimensional Driving Simulator, Proc. of
SICE Annual Conference, 1779~1783, 2003

- 14) 杉原敏夫, 藤田渉: 多変量解析, 牧野書店, 1998