自動車走行時における道路状況認識と 運転者の意図分析アルゴリズム

正員 佐藤 光 男 (東 北 大)

正員 竹 田 宏 (東 北 大)

非会員 富 澤 尚 己 (日本電子機器)

非会員 今 村 政 道 (日本電子機器)

非会員 酒 井 明 彦 (キ ャ ノ ン)

Algorithms of Road Circumstances Recognition and Driver's Intention Analysis in Driving Vehicle

Mitsuo Sato, Member, Hiroshi Takeda, Member (Tohoku University), Naoki Tomizawa,
Non-member, Masamichi Imamura, Non-member (JECS CO., LTD.), Akihiko Sakai,
Non-member (CANON INC.)

In this paper, we consider the problems of recognizing road circumstances of a vehicle and analyzing driver's intention based on information obtained from some sensors attached to the vehicle. For these problems, first we show that it is sufficiently possible to identify the circumstances and it is possible to some extent to identify intention by using a number of feature extraction variables which are made by appropriate feature extraction, e. g. averaging or counting during a certain period, from measurement data of the sensors. Then, based on this consideration, we present two kinds of algorithms. One makes the identification by Mahalanobis' generalized distance on a vector space generated from the feature extraction variables, and the other by fuzzy reasoning with using membership functions, each of which is made for each feature extraction variable. By applying these algorithms to actual sensor measurement data, we show that they provide a success rate of more than 90% concerning recognition of road circumstances and a success rate of more than 70% concerning analysis of some driver's intention.

キーワード：自動車，パワートレイン系，道路状況認識，意図分析

1. はじめに

近年のカーエレクトロニクス技術，特にマイクロコンピュータによるエンジン，変速機，シャシ，サスペンション，ブレーキなどの電子制御技術の進歩は目覚ましいものがある^{(1)~(4)}。従来，これら各機構の制御は個別的なものであったが，今後は車両全体の総合制御化へ進む方向にある⁽¹⁾⁽²⁾。このような総合制御化は，単に各機能の情報共有による制御性能の向上を目的とするだけでなく，従来の制御にはなかった新しい概念に基づく，より高度の制御の導入を可能とする。

本研究では，動力の発生から伝達をつかさどるエンジン，クラッチ，変速機からなるパワートレイン系を対象として，総合制御の一つである運転環境適合制御の実現を目指す。運転環境適合制御とは，道路状況や運転者の意図に応じて自動車の走行特性を常に最適化する制御である。現在のオートマチック車において，車速とスロットル開度に応じて，ギヤ切替時点を定めるいわゆるシフトスケジュールを例にとってみる。排気，燃費，安全性などの面からみれば，渋滞走行と高速走行とでは，またスポーティな走行とゆっくりな走行とでは要求されるシフトスケジュールが異なる。こ

のシフトスケジュールをはじめエンジンレスポンス、エンジン出力、サスペンション、車高など自動車の走行特性を決定する種々のパラメータを、道路状況や意図に応じて総合的に制御することにより、排気や燃費の特性を向上させ、意図と車両の挙動とのずれから生じる危険を低減しようというのが運転環境適合制御の目的である。その実現のためには、自動車に取付けられた一般的な車載センサの計測値をもとに、道路状況認識や意図分析を正確かつ効率的に行うアルゴリズムが必要となる^{(6)~(7)}。

このような観点から、本論文では、道路状況の認識および運転者の意図分析に関して、それぞれまずその可能性について十分検討し、その結果をもとに道路状況認識および意図分析のアルゴリズムを構築する。

道路状況認識では、現在の車両の特性向上を図る立場からはシフトスケジュールなどのパラメータは人間の大ざっぱな状況の分類に応じて5通り程度に変変するのが技術的・経済的に有利であるとの考えに基づき、一般的な車載センサを用いて運転者の判断を自動化するシステムの開発を試みる。そこでここでは、道路状況を定量的にあるいは数多くの種類に分類するのではなく、人間の判断に基づきすべての状況を市街、渋滞、登坂、降坂、高速の五つに分類し、それらを識別することを目的とする。それらの定義については、運転者が走行中に渋滞と判断すればそれを渋滞、登坂と判断すれば登坂、降坂と判断すれば降坂、高速道路を通常に走行しているときは高速、そしてこれらに当てはまらないものを市街とする。幾つかのセンサ計測値から有用なものを選出し、それに一定時間内の平均操作など適当な特徴抽出を行えば、道路状況の特定が十分可能であるという検討結果をもとに、距離による多変量の判別分析手法およびファジィ推論の手法を用いてアルゴリズムを構築する。意図分析では、急いで、普通に、ゆっくりという三つの意図を識別することを目的とする。ここに、“急いで”は急いで走行しよう意識している状態の意図、“ゆっくり”はゆっくり走行しよう意識している状態の意図とそれぞれ定義し、“普通に”はそれらのように特に意識はしていないごく普通の状態の意図と定義する。ただし、同じ意図のもとでも運転行動は道路状況により異なってくるので、認識アルゴリズムにより道路状況は既に認識されたものとして、その状況のもとで同様なアルゴリズムにより意図分析を行うものとする。更に、提案アルゴリズムの有効性を検証するために、それらを実走行データに適用した道路状況認識および意図分析の結果を示す。

2. 運転環境適合制御

現在、自動車に取入れられている電子制御系においては、走行特性を決定する種々のパラメータのほとんどが常に固定されている。しかし、それらのパラメータ設定値はどのような状況のもとでも最適であるとは限らない。そこで、そのようなパラメータを道路状況や運転者の意図に応じて改変することにより、地球環境対策、燃費、安全性などの面から走行特性を最適化しようというのが運転環境適合制御の目的である。この制御は、具体的には、センサ出力をもとに道路状況認識および意図分析を行い、その結果に基づいて車両総制御部の種々のパラメータを自動的に変化させるというものである。この道路状況認識や意図分析をいかに正確にかつ効率的に行うかが、ここでの重要な問題である。

自動車に取付けられた各種センサの計測値によって道路状況認識や意図分析が、どの程度正確に行えるかを調べるために、道路状況や意図とセンサ計測値との相関関係を明らかにする必要がある。そのために、ある固定した道路状況あるいは意図のもとで実車走行試験を実施し、その際得られたセンサ計測データを道路状況別および意図別に詳しく分析する。本研究における実車走行試験は、2,000 CC クラスのオートマチックトランスミッション式普通乗用車1台を使用し、群馬県伊勢崎市内とその周辺の一般道路上で、1回の試験の継続時間を15~40分程度として6人の運転者により合計45回行われた。道路状況認識については4人により計15回、意図分析については2人により計30回行われた。これらの6人は、いずれもある自動車関連企業に所属し、自動車の性能テストなどにしばしば採用される運転者である。なお、道路状況認識についての試験は、意図を特に指定せずに行われた。本試験で計測された諸量は、(1)ブレーキのON/OFF、(2)エンジンオイル温度、(3)エンジン排気温度、(4)吸気管圧(ブースト)、(5)大気圧、(6)横方向加速度、(7)エンジン回転数、(8)エンジン流入空気量、(9)冷却水温度、(10)ギヤ位置、(11)車速、(12)アクセル開度、(13)AT(オートマチックトランスミッション)オイル温度である。これらを計測するセンサは、(2)と(6)を除いて、いずれも車載用としては一般的かつ安価なものである。上記(1)はブレーキを踏んだか否かを、それぞれ正の一定値あるいは0で区別するもの、(10)はATのギヤが1速から4速のどれに入っているかを示すもの、(12)はアクセルペダルの踏み込み角度である。

以下、上記の諸量をもとに正確な道路状況認識や意図分析が十分可能かどうかを検討したうえで、それぞれのアルゴリズムを構築する。

3. 道路状況の認識

〈3・1〉 センサ計測データからの特徴抽出 前記の実車走行試験で収集された、2人の運転者による道路状況別のセンサ計測データの例を図1に示す。これは、高速を除く四つの状況が同一の運転者、高速が別の運転者によるもので、上記(1)、(6)、(7)、(8)、(11)の計測値の時系列データを、ある60秒の区間だけ切取って示したものである。これを見れば道路状況の違いを容易に識別することができる。各種計測データを視察により調べた結果、上記5種類の計測値が道路状況を認識するために特に有効であることがわかった。図1を見て道路状況の違いが直ちにわかることは、著者らが5種類のデータの時間的変動パターンの相違から、全体的な特徴を抽出していることを意味する。認識に要するデータ長を T_d (s) で表す。明らかに T_d が短くなるにつれて、データから道路状況を特定するのが困難になる。しかし一方、 T_d を長くすると、当然認識のための時間が長くなり、その間に道路状況の変化が起きてもそれに速やかには追従できなくなる。従って、 T_d はデータから十分な特徴抽出ができる範囲内でできるだけ短くとることが望ましい。以上のように、認識を自動化するにあたっては、まず T_d の値の設定を含めた特徴抽出が重要な問題となる。そこで、 T_d の値を設定するために、 $T_d=30, 60, 90, 120$ s の各場合について、特徴抽出を試みる。上に述べたことから、この特徴抽出は T_d 間における各種データの時間的変動を定量的に表すものでなければならない。もちろん、この表し方は一通りとは限らず、それぞれのデータについて適切なものを考えなければならない。ここでは、上記5種類にギヤ位置を加えたデータから、連続的な変化量に対しては平均操作およびON/OFFのような2値情報に対しては、カウント操作などを施すことにより、次の7種類の特徴抽出変数を作成する。

- x_{e1} : T_d 間平均車軸トルク
- x_{e2} : T_d 間車両停止時間割合
- x_{e3} : T_d 間ブレーキ踏み時間割合
- x_{e4} : T_d 間ブレーキ踏み回数
- x_{e5} : T_d 間平均車速
- x_{e6} : T_d 間車速標準偏差
- x_{e7} : T_d 間横方向加速度標準偏差

ここに、添え字 e は道路状況を意味する。上記 x_{e2} ,

①: ブレーキ ON/OFF, ②: 横方向加速度, ③: エンジン回転数, ④: エンジン流入空気量, ⑤: 車速

図1 道路状況別の60秒間のセンサ計測データの例

Fig.1. Example of sensor measurement data during 60 seconds obtained under each of road circumstances.

x_{e5} , x_{e6} は車速, x_{e3} と x_{e4} はブレーキ ON/OFF, x_{e7} は横方向加速度の各データからそれぞれ作成されたものである。これに対して、重要な情報である車軸トルクが、エンジンの回転数と流入空気量にギヤ位置の情報を加えれば近似的に求められることに着目し、ギヤ位置のデータも加えた3種類のデータから作成したのが x_{e1} である。すなわち、車軸トルクは、エンジンの流入空気量をエンジン回転数で割ったものに全減速比

(本試験車両では1速時:2.842, 2速時:1.542, 3速時:1.000, 4速時:0.686)をかけることにより求められ⁽⁸⁾, このようにして求めたトルクの T_d 間の時間平均が x_{e1} である。 x_{e3} と x_{e4} についてはともに車両停止時間を考慮に入れないものとする。この特徴抽出には, 図1の例と同じ2人の運転者によるデータ長が, それぞれ15分程度の道路状況別走行データを用いる。また, 特徴抽出変数の値はサンプリング間隔 T_s ごとに更新される。なお, 本研究では使用機器の特性から $T_s=0.4$ s である。

このようにサンプリング時刻ごとに求めた各特徴抽出変数のヒストグラムを調べた結果, 特に T_d 間平均車軸トルク x_{e1} と T_d 間平均車速 x_{e5} の二つのヒストグラムを組合せた場合に, 道路状況の違いによる有意差が顕著に現れた。変数 x_{e1} と x_{e5} をそれぞれ縦軸と横軸にとり, 上記データをもとに各サンプリング時刻において得られた値をこの座標上にプロットしたものを, 4種類の T_d に対して示したのが図2である。同図からわかるように, $T_d=120, 90$ s の場合には, 同じ道路状況に属するサンプル点はいずれも一つのカテ

図2 各道路状況(1:市街, 2:渋滞, 3:登坂, 4:降坂, 5:高速)のもとで各サンプリング時刻において得られた特徴抽出変数値 x_{e1}, x_{e5} の二次元座標表示
Fig.2. Plotted values of x_{e1} and x_{e5} evaluated at all sampling times by using data under each of road circumstances, 1: town, 2: congestion, 3: ascent, 4: descent, 5: highway.

グリーを形成している。カテゴリー間において, 多少重複する領域が存在するものの, 上記二つ以外の特徴抽出変数も用いれば, 道路状況が五つのうちのどれであるかを高精度で特定できるものと考ええる。しかし, $T_d=60, 30$ s と短くなるにつれて, 各状況においてサンプル点のばらつきが大きくなる。このため, カテゴリー間の重複領域が拡大し, 道路状況識別は困難になる。以上から, ここでは T_d の値として90と120を設定する。

〈3・2〉 道路状況認識アルゴリズム 前記7種類の特徴抽出変数から各サンプリング時刻において道路状況の認識を行うわけであるが, 本論文では, 多変量の判別分析に用いられるマハラノビス汎距離⁽⁹⁾と, ファジィ推論によって認識を行う二つのアルゴリズムを考える。

(1) マハラノビス汎距離を用いたアルゴリズム 次のような特徴抽出変数を成分とする七次元ベクトル x_e を定義する。

$$x_e = (x_{e1} \ x_{e2} \ \dots \ x_{e7}) \dots\dots\dots (1)$$

あらかじめ得られている十分長い道路状況別の実走行データにおいて, サンプリング時刻を $n=1, \dots, N_e$ とし, 時刻 n における x_e の値を $x_e(n)$, またそれらの重心ベクトルを

$$x_e^* = \frac{1}{N_e} \sum_{n=1}^{N_e} x_e(n) \dots\dots\dots (2)$$

と表す。なお以下, 道路状況が特に市街 (town), 渋滞 (congestion), 登坂 (ascent), 降坂 (descent), 高速 (highway) を表すときは, それぞれ $e=t, c, a, d, h$ と書く。ここで提案するアルゴリズムは, 道路状況未知の入力ベクトル $x_e = x$ が与えられたとき, x と各状況 e に対する x_e^* とのマハラノビス汎距離 $D(x, x_e^*)$ を求め, それが最小となる状況を認識結果として出力するものである。 $D(x, x_e^*)$ は次式で与えられる。

$$D(x, x_e^*) = \sqrt{(x - x_e^*) \Sigma^{-1} (x - x_e^*)^T} \dots\dots\dots (3)$$

(T : 転置)

ここに, 重み付け行列 Σ^{-1} の逆行列 Σ は次のように与えられる。

$$\Sigma = \frac{N_t S_t + N_c S_c + N_a S_a + N_d S_d + N_h S_h}{N_t + N_c + N_a + N_d + N_h}$$

ただし, S_e はその (i, j) 要素が

$$\sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [x_{ei}(n) - x_{ei}^*(n)][x_{ej}(n) - x_{ej}^*(n)]}$$

なる 7×7 行列である。このように, マハラノビス汎距離は, 入力ベクトルと状況別重心ベクトルとの単なる2点間の距離だけでなく状況別データ群の広がりも

考慮したものとなっている。

(2) ファジィ推論によるアルゴリズム ここで提案するアルゴリズムは、次のように記述されるファジィルールに基づくものである。

あらかじめ得られている十分長い道路状況別の実走行データによる特徴抽出変数 $x_{e1}, \dots, x_{e7}$ のヒストグラムの形を、それぞれ近似するような台形型のメンバシップ関数(以下、MS 関数と呼ぶ) $f_{e1}, \dots, f_{e7}$ を作成しておく。いま、道路状況未知の入力ベクトル $x = (x_1, \dots, x_7)$ が与えられたとする。 x の状況 e への所属の度合(グレード)を、それぞれの成分に対するグレードの最小値(論理積)すなわち、

$$\min_{i \in I_e} f_{ei}(x_i) = a_e \quad \dots \dots \dots (4)$$

で表すこととし、 a_e を最大にする e を認識結果とする。ここに、 I_e は $i=1, \dots, 7$ からなる集合であるが、(4)式の最小化において、7種類すべての特徴抽出変数を考慮すること、すなわち $I_e = \{1, \dots, 7\}$ とすることが必ずしも良い認識結果をもたらすとは限らないので、最も良い認識結果が出るような I_e を各状況 e に対して試行錯誤的に設定した。

〈3・3〉 実走行データを用いた認識結果 前節で提案した二つのアルゴリズムを、実走行データに適用した道路状況認識の結果を示す。認識に用いたデータは4人の運転者によるもので、特徴抽出変数の決定に用いた前記15分程度の状況別データをそれぞれなかに含む市街45分、渋滞85分、登坂25分、降坂25分、高速35分の走行データである。これらはいずれも、4人の運転者による走行データから道路状況別にデータを切出したものを、同じ状況ごとに、適当な順につなぎ合わせたものである。まず、これら各データの前半部を用いて、 $e=t, c, a, d, h$ に対して重心ベクトル x_e^* を求めるとともに、MS関数 $f_{e1}, \dots, f_{e7}$ を作成する。作成したMS関数の1例として $f_{t1}, \dots, f_{t7}$ を図3に示す。次に、各データの後半部を用いて両アルゴリズムにより道路状況の認識を行った。その結果を $T_d=90$ s と $T_d=120$ s の二つの場合に分け、それぞれ表1と表2に示す。表中の認識率は、認識がなされた全時点数に対する、正しい認識がなされた時点数の割合(%)である。ここに、(4)式の I_e については

$$I_t = \{1, 2, 5, 7\}, \quad I_c = \{3, 5, 6\},$$

$$I_a = \{1, 3\}, \quad I_d = \{1, 3, 7\}, \quad I_h = \{2, 3, 5\}$$

と設定したときが最も高い認識率を得たので、表にはそのときの結果を記した。

これらの結果では誤った認識のほとんどは市街と渋滞との取違えであるが、渋滞の判断は主観にもよるこ

とを考えれば、特に $T_d=120$ の場合の認識率はかなり高いといえる。ただし $T_d=120$ の場合は $T_d=90$ の場合よりも状況の変化に対する追従性は劣化するので、この点について今後、道路状況の変化を多く取込んだ走行データを用いて認識率を調べる必要がある。将来は、状況の急な変化にも速やかに追従できるよう

図3 メンバシップ関数の例
Fig.3. Example of membership function $f_{t1}, \dots, f_{t7}$.

表1 $T_d=90$ の場合の提案アルゴリズムによる道路状況認識率

Table1. Rate of true recognition when applying the two algorithms to the road circumstances recognition with setting $T_d=90$.

	マハラノビス汎距離 によるアルゴリズム	ファジィ推論による アルゴリズム
認 識 率	88.9%	88.9%
誤認識の内訳	市 街 → 渋 滞	市 街 → 渋 滞
	7.1%	5.0%
	渋 滞 → 市 街	渋 滞 → 市 街
	4.0%	6.8%
		市 街 → 降 坂
		0.1%

表 2 $T_d=120$ の場合の提案アルゴリズムによる道路状況認識率

Table 2. Rate of true recognition when applying the two algorithms to the road circumstances recognition with setting $T_d=120$.

	マハラノビス汎距離によるアルゴリズム	ファジィ推論によるアルゴリズム
認識率	93.3%	94.2%
誤認識の内訳	市街 → 渋滞 4.0%	市街 → 渋滞 3.7%
	渋滞 → 市街 2.7%	渋滞 → 市街 2.1%

に T_d の値を常に何通りか設定しておく方法などについても検討する必要がある。

また、マハラノビス汎距離とファジィ推論による二つのアルゴリズムの比較については、これら認識率に関する結果だけでは両者の優劣を断定することはできない。後者は、MS 関数をどのように作成したらよいかや、 I_e をどのように設定したらよいかを考えねばならないなど直観的・経験的な点もあるが、マハラノビス汎距離を求める計算が複雑な前者に比べて計算量が少ないという大きな利点があり、実用上は後者のほうが有効である。

なお、本論文では省略したが、道路状況認識に用いる距離としてマハラノビス汎距離以外の、例えば重み付きユークリッド距離などを用いたときや、本論文で用いた以外の形の MS 関数を用いたときにはいずれも認識率は 70% に満たず、かなり大幅に低下することが確かめられている。

4. 運転者の意図分析

意図分析と道路状況認識との大きな違いは、識別対象である意図が道路状況よりも、更に主観的かつあいまいであるという点にある。また、同じ意図のもとでも運転行動は道路状況により異なってくる。そのため、意図分析は道路状況認識よりも困難であることが予想される。

これらの点を念頭に置き、運転者の意図分析の可能性について検討し、アルゴリズムを構築する。意図分析の基本的手法は道路状況認識と同様 2 種類であるが、ここでは、急いで (fast)、普通に (normal)、ゆっくり (slow) の三つを識別することを目的とする。ただし、認識アルゴリズムにより道路状況が既に認識されたものとして、その状況のもとで意図分析を行うものとする。

〈4・1〉意図を反映した特徴抽出変数の作成

道路状況認識の場合と同様に、実走行データを用いて、意図を反映した特徴抽出変数を作成する。用いるデータは、2 人の運転者 A, B について道路状況別に 3 通りの意図状態のもとで取得した 10~15 分間のセンサ計測データである。運転者 B については走行試験を 2 回行っている。なお、渋滞時の走行については、意図の違いが運転行動に反映されにくいという理由から、また降坂時の fast 走行については、走行試験そのものが危険であるという理由からそれぞれデータの取得を行わなかった。

まず、意図を強く反映するセンサ計測値を、次のような二つの観点から選ぶ。一つは、意図が反映されやすい運転行動に関する情報を含むことである。いま一つは、運転者自身が比較的容易に知る、あるいは感じることができる情報を含むことである。このような情報は意図や行動に影響を与える可能性が強いので意図分析に役立つ。前記の 13 のセンサ計測値のなかから、前者の観点からフットブレーキの ON/OFF とアクセル開度、後者の観点から車速を選ぶ。 T_d については、前章の結果を参考にして、 $T_d=120$ s と設定し、平均操作やカウント操作によって、これらのデータの T_d 間における時間的変動を表す、特徴抽出変数を下記のように 7 種類作成する。特に運転者の意図が強く反映するアクセル操作のデータからは、アクセルペダルをどの程度深く、どの程度急に、更にはまたどの程度頻繁に踏んだかを表すために 4 種類の特徴抽出変数を作成する。

- x_{i1} : T_d 間平均アクセル開度
- x_{i2} : T_d 間アクセル開度標準偏差
- x_{i3} : T_d 間平均アクセル開速度
- x_{i4} : T_d 間アクセル開速度 ON/OFF 回数
- x_{i5} : T_d 間ブレーキ踏み時間割合
- x_{i6} : T_d 間ブレーキ踏み回数
- x_{i7} : T_d 間平均車速

ここに、添え字 i は意図 (intention) を意味し、アクセル開速度とはアクセル開度の時間微分値である。また、 x_{i4} はアクセルの素早いオン・オフをカウントするもので、開速度が 10 deg/s 以上になったときは ON、同じく -10 deg/s 以下になったときは OFF として T_d 間でその回数を数えたものである。

これら各特徴抽出変数の平均値と標準偏差について、三つの意図を比較してみると、1 人の運転者については、幾つの特徴抽出変数において意図による有意差が見られる。図 4、図 5 はその代表例を二つ示したものである。これらの図は、ある道路状況のもとで

図 4 運転者 A, B による市街走行の場合の特徴抽出変数 x_{13} の平均値と標準偏差 (No. 1 と No. 2 はそれぞれ運転者 B の 1 回目と 2 回目の走行試験に対応)

Fig. 4. Mean value and standard deviation of feature extraction variable x_{13} during town driving by drivers A and B (No. 1 corresponds to the first driving test by driver B and No. 2 to the second).

図 5 運転者 A, B による高速走行の場合の特徴抽出変数 x_{17} の平均値と標準偏差 (No. 1 と No. 2 は図 4 に同じ)

Fig. 5. Mean value and standard deviation of feature extraction variable x_{17} during highway driving by drivers A and B (No. 1 and No. 2 are the same as in Fig. 4).

運転者 A, 同 B の 1 回目 (No. 1) および 2 回目 (No. 2) の意図別走行データから得られたある特徴抽出変数の平均値と標準偏差を表したものである。図中各線分の中点が平均値、中点から一方の端点までの距離が標準偏差を表す。図 4 は市街の場合の x_{13} 、図 5 は高速の場合の x_{17} についてのものである。これらの図からわかるように、特に A については、市街の場合の x_{13} と高速の場合の x_{17} においていずれも意図による有意差がはっきり表れている。しかし B については、1 回目と 2 回目の両走行を通して意図による有意差が A に比べてはるかに不明確である。明らかに、B のような運転者については意図分析は困難である。

運転者 A の意図分析の可能性を更に追求するために、意図による有意差に時間的な不変性があるかどうかを調べる。しかし A の走行試験は 1 回しか実施していないので、ここでは図 4、図 5 の作成に用いた走行データを時間的に 2 分割し、それによって得られる二つのデータについて上図内容と同じことを調べる。その結果を示したのが図 6、図 7 である。図 6 は市街の

図 6 運転者 A による市街走行の場合の特徴抽出変数 x_{13} の平均値と標準偏差 (No. 1 と No. 2 はそれぞれ走行試験の前半部分と後半部分に対応)

Fig. 6. Mean value and standard deviation of feature extraction variable x_{13} during town driving by driver A (No. 1 corresponds to the first half part of a driving test and No. 2 to the latter half).

図 7 運転者 A による高速走行の場合の特徴抽出変数 x_{17} の平均値と標準偏差 (No. 1 と No. 2 は図 6 に同じ)

Fig. 7. Mean value and standard deviation of feature extraction variable x_{17} during highway driving by driver A (No. 1 and No. 2 are the same as in Fig. 6).

場合の x_{13} 、図 7 は高速の場合の x_{17} についてのもので、図中 No. 1 とあるのが前半の走行データ、No. 2 とあるのが後半の走行データにそれぞれ対応する。これらの図によれば A の意図による有意差はほぼ不変であり、このような運転者については特徴抽出変数を適当に選ぶことにより意図分析は十分に可能である。

〈4・2〉意図分析アルゴリズム 前節の結果に基づいて、運転者 A の道路状況別走行データについて意図を分析するアルゴリズムを構築する。

そのためにまず、前記 $x_{11}, \dots, x_{17}$ のなかから各意図の特定に有効な特徴抽出変数を選定する。選定にあたっては、まず、前記と同様に前半と後半に分割された二つの走行データから各変数の平均値と標準偏差を求める。次に、前半部と後半部とで、ある意図のほかに対する有意差が明確で一貫しているならば、その変数はその意図の特定に有効であると判断する。このようにして選定された、道路状況別各意図の特定に有効な特徴抽出変数の一覧を表 3 に示す。

これらの特徴抽出変数をもとに、道路状況認識の場

表 3 道路状況別各意図の特定に有効な
特徴抽出変数

Table 3. List of feature extraction variables useful for identifying each intention under given road circumstances.

道路状況	意 図	意図の特定に有効な特徴抽出変数
市 街	slow	$x_{11}, x_{12}, x_{13}, x_{14}, x_{17}$
	normal	x_{12}, x_{13}
	fast	$x_{11}, x_{12}, x_{13}, x_{14}$
高 速	slow	x_{11}, x_{17}
	normal	x_{17}
	fast	x_{17}
登 坂	slow	$x_{11}, x_{12}, x_{15}, x_{16}$
	normal	x_{12}, x_{15}
	fast	x_{12}, x_{15}
降 坂	slow	x_{11}, x_{12}, x_{15}
	normal	x_{11}, x_{12}

合と全く同様に、マハラノビス汎距離とファジィ推論による二つのアルゴリズムを考える。

前者のアルゴリズムについては、表 3 を参照することにより、道路状況ごとに (1) 式のベクトル x_e に対応するベクトル x_i を設定する。すなわち、

市街に対しては

$$x_i = (x_{12}, x_{13})$$

高速に対しては

$$x_i = x_{17}$$

登坂に対しては

$$x_i = (x_{12}, x_{15})$$

降坂に対しては

$$x_i = (x_{11}, x_{12})$$

とそれぞれ設定する。

これらのアルゴリズムを、運転者 A の同上道路状況別走行データに適用して、分析がなされた全時点数に対する、正しい分析がなされた時点数の割合を調べたところ、表 4 の結果が得られた。マハラノビス汎距離によるアルゴリズムについては、データの前半部を用いて (2) 式の x_e^* に対応する重心ベクトル x_i^* を求め、データの後半部を用いて分析を行った。ファジィ推論によるアルゴリズムについては、データの前半部を用いて $x_{11}, \dots, x_{17}$ のヒストグラムの形から必要な MS 関数を作成し、(4) 式の I_e に対応する I_i としては、幾つか試みたうち最も結果の良かったものを採用した。すなわち、

市街走行時の分析については

表 4 提案アルゴリズムによる運転者 A の
道路状況別の意図分析率

Table 4. Rate of true analysis when applying the two algorithms to analyze driver A's intention under each of road circumstances.

	マハラノビス汎距離 によるアルゴリズム	ファジィ推論による アルゴリズム
市 街	75.6%	80.4%
高 速	95.8%	95.6%
登 坂	80.1%	73.5%
降 坂	78.0%	80.1%

$$I_s = \{3, 4, 7\}, \quad I_n = \{2, 3\},$$

$$I_f = \{1, 2\}$$

高速については

$$I_s = \{1, 7\}, \quad I_n = I_f = \{7\}$$

登坂については

$$I_s = \{2, 5, 6\}, \quad I_n = I_f = \{5\}$$

降坂については

$$I_s = I_n = \{2\}$$

とした。ここに添字の $i=s, n, f$ はそれぞれゆっくり、普通に、急いでは対応する。そして、データの後半部を用いて分析を行った。表 4 の意図分析率は表 1 の道路状況認識率よりもだいぶ低く、やはり意図分析は道路状況認識よりも困難であることがわかる。

表 4 によれば二つのアルゴリズムによる分析率は全体としてほぼ同等であるが、道路状況認識の場合と同様、ファジィ推論によるほうが計算量が少ないという運用上の利点がある。

5. おわりに

本論文では、近い将来に普及するであろう自動車の運転環境適合制御を実現するのに不可欠な、道路状況の認識と運転者の意図分析を行うアルゴリズムを構築した。

道路状況認識では、市街、渋滞、登坂、降坂、高速の五つを識別することを目的とし、まず、実車走行試験により得られたブレーキ ON/OFF や車速など 6 種類のセンサ計測データから T_d 間の平均車軸トルクや平均車速など 7 種類の特徴抽出変数により、特徴抽出を行えば道路状況の認識が十分可能であることを示した。次いで、これらの特徴抽出変数をもとに、マハラノビス汎距離とファジィ推論による二つのアルゴリズムを構築した。両アルゴリズムを実走行データに適用したところ、どちらについても $T_d=120$ の場合は

93~94%の認識率が得られた。この場合の誤認識がすべて、元来境界のあいまいな市街と渋滞の取違えであることを考えれば、得られた認識率は両アルゴリズムとも十分高いものである。ただし、計算量が少ないという点で、ファジィ推論によるほうが実用上は有効である。意図分析では、道路状況は既に認識されたものとして、そのもとで、急いで、普通に、ゆっくりの三つを識別することを目的とした。ある運転者の走行データに対して、意図を反映した適当な特徴抽出変数を作成し、道路状況認識と同様二つのアルゴリズムを構築して適用したところ、70%以上の分析率が得られた。他の運転者については、運転行動からみる限り意図は不明確でその分析が困難であった。このように、道路状況認識と同様のアルゴリズムでは、道路状況よりも主観的かつあいまいな意図の分析は困難で、しかもその場合は運転者によって異なることが確かめられた。そこで、意図分析アルゴリズムが実用化されるには、種々の運転者に適用可能となるようにアルゴリズムを改善することが必要である。そのための一つの方策は、最初は特定の運転者に対して重心ベクトル x_i^* あるいはMS関数を作成しておき、新たなデータが入るたびに古いデータを消去して x_i^* あるいはMS関数を更新するなどの方法により、運転者が変わってもそれに適応できるようにアルゴリズムを拡張するというものである。

今後の検討課題として、上記のような意図分析アルゴリズムの拡張のほか、認識や分析の速応性に関する T_d の最適な設定を、より多くのサンプルのデータを用いて検討することが挙げられる。これらの検討と同時に、提案手法の実用化のためには、そのハードウェア化、オンボード化が必要である。

最後に、本研究を進めるにあたりデータの提供および有益な討論など種々御協力いただいた、茂木高明、渡辺 悟の両氏をはじめとする日本電子機器(株)の方々に深く感謝する。

(平成4年10月26日受付, 同5年1月27日再受付)

文 献

- (1) 志賀・水谷:カーエレクトロニクス(昭61)山海堂
- (2) 青野:自動車エレクトロニクス(平1)工業調査会
- (3) 乾:「自動車のパワートレーンエレクトロニクス」, 電学誌, 110, 268 (平2-4)
- (4) 青野:「シャシエレクトロニクス」, 同上, 110, 273 (平2-4)
- (5) 酒井・佐藤・吉澤・竹田・今村:「自動車走行時の環境認識および意図分析について」, 第33回自動制御連合講演会前刷, p. 235 (平2)
- (6) 佐藤・竹田・酒井・今村:「自動車走行時の環境認識および意図分析アルゴリズム」, 第30回計測自動制御学会学術講演会予稿集, p. 335 (平3)
- (7) 高橋・南:「ファジィ推論による自動車の走行道路認識」, フ

アジィ学誌, 2, 438 (平2-8)

- (8) 三浦・福田:自動車設計と解析シミュレーション(平2)培風館
- (9) 田中・脇本:多変量統計解析法(昭63)現代数学社

佐 藤 光 男 (正員)

昭和25年1月26日生。52年東北大学大学院工学研究科博士課程修了。同年同大学工学部助手, 62年同助教となり, 現在に至る。工学博士。確率システムおよび学習制御の研究に従事。計測自動制御学会, 電子情報通信学会会員。

竹 田 宏 (正員)

昭和34年東北大学大学院工学研究科博士課程修了。同年富士通(株)入社。35年東北大学電気通信研究所助手, 37年同大学助教授, 48年同教授となり, 現在に至る。工学博士。最適推定理論, 手動制御系の数学的モデルの研究などに従事。IEEE, 計測自動制御学会, 電子情報通信学会, 日本エム・イー学会会員。

富 澤 尚 己 (非会員)

昭和53年慶応義塾大学理工学部卒業。同年日本電子機器(株)入社。現在, 同社設計部システム課主査。自動車エンジン, 電子燃料噴射のマイコン制御システムの開発に従事。

今 村 政 道 (非会員)

昭和61年北見工業大学応用機械工学科卒業。同年日本電子機器(株)入社。現在, 同社勤務。自動車エンジン, サスペンションの電子制御システムの開発に従事。

酒 井 明 彦 (非会員)

平成3年東北大学大学院工学研究科修士課程修了。同年キャノン(株)入社。現在, 同社勤務。在学中は, 自動車走行時の環境認識, 意図分析の研究に従事。