

# 学習理論を用いた自動車の 運転環境適合制御に関する研究

佐藤 光男

東北工業大学 通信工学科

## 1. まえがき

マイクロコンピュータの普及による自動車の電子制御技術の進歩は最近めざましいものがある。自動車各機構の制御はこれまで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<sup>(1)・(2)</sup>。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き、より高度の制御の導入を可能とする。本研究では、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、道路の環境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。現在市販されているほとんどの自動車において、オートマチック車用のギヤシフトパターンをはじめ、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はあらかじめ固定されている。これら総合制御部の各パラメータを環境や運転者の意図に応じて最適に調整すれば、排気、燃費、安全性などの面でかなりの改善が期待できる。これが運転環境適合制御の目的である。その実現のためには、自動車走行時に一般的な車載センサの計測データをもとに環境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<sup>(3)・(4)</sup>。

本研究では、距離による多変量判別分析とファジィ推論の二つのパターン認識手法を用いた環境認識および意図分析アルゴリズムを構築する。環境認識では、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、意図分析では、急いで、普通に、ゆっくりの三つを識別することを目的とする。これらのアルゴリズムを実走行データに適用することにより、その実用化に向けての有効性を検証する。

## 2. 実車走行試験によるデータ収集

自動車に取り付けられた各種センサの計測値によって環境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、環境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、ある固定した環境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環境別および意図別に詳しく分析す

る。本試験は、2000CCクラスのAT（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、I市内とその周辺の一般道路上で複数の運転者により実施された。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。

以下、上記の諸量をもとに正確な環境認識や意図分析が十分可能かどうかを検討した上で、それぞれのアルゴリズムを構築する。

### 3. 道路環境の認識

#### 3.1 センサ計測データからの特徴抽出

前記五つの環境の定義については、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。ある自動車関連企業に所属し、自動車の性能テスト等にしばしば採用される複数の運転者による前記走行試験で収集された環境別のセンサ計測データの例を図1に示す。これは上記(1)、(6)、(7)、(8)、(11)の計測値の時系列データを、ある60秒の区間だけ切り取って示したものである。これを見れば環境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種類の計測値が環境を認識するために特に有効であることがわかった。図1を見て環境の違いが直ちにわかることは、我々が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 $T_d$ [秒]で表す。明らかに $T_d$ が短くなるにつれてデータから環境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、その間に環境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。そこで、 $T_d$ の値を設定するために、 $T_d = 30, 60, 90, 120$ [秒]の各場合について、次の7種類の変数を作成することにより特徴抽出を行う。

$x_{e,1}$  :  $T_d$ 間平均車軸トルク

$x_{e,2}$  :  $T_d$ 間車両停止時間割合

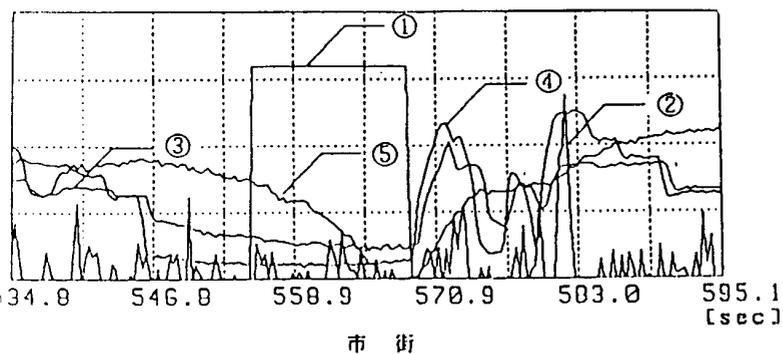
$x_{e,3}$  :  $T_d$ 間ブレーキ踏み時間割合

$x_{e,4}$  :  $T_d$ 間ブレーキ踏み回数

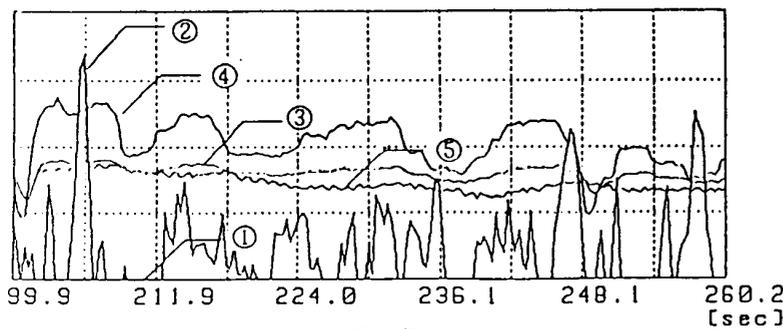
$x_{e,5}$  :  $T_d$ 間平均車速

$x_{e,6}$  :  $T_d$ 間車速標準偏差

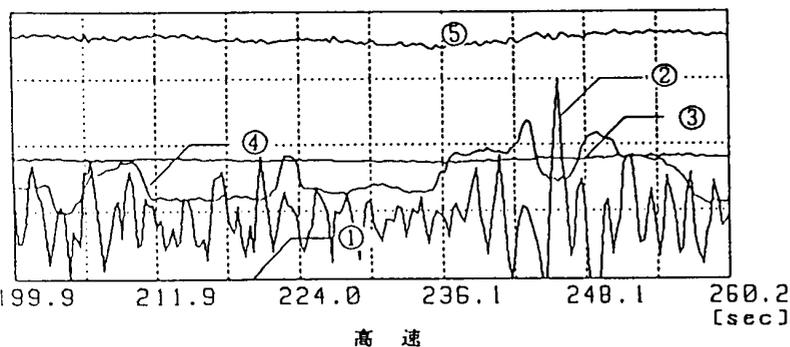
$x_{e,7}$  :  $T_d$ 間横方向加速度標準偏差



市街



登坂



高速

図1 環境別のセンサ計測データの例

のとする。この特徴抽出には、データ長が15分程度の環境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  $T_s = 0.4$  [秒] 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 $T_s$ 間平均車軸トルク $x_{e1}$ と $T_s$ 間平均車速 $x_{e5}$ の二つのヒストグラムを組み合わせた場合に、環境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、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 $T_s$ に対して示したのが図2である。図2からわかるように、 $T_s = 120, 90$  [秒] の場合には、同じ環境に属するサンプル点はいずれも一つのカテゴリーを

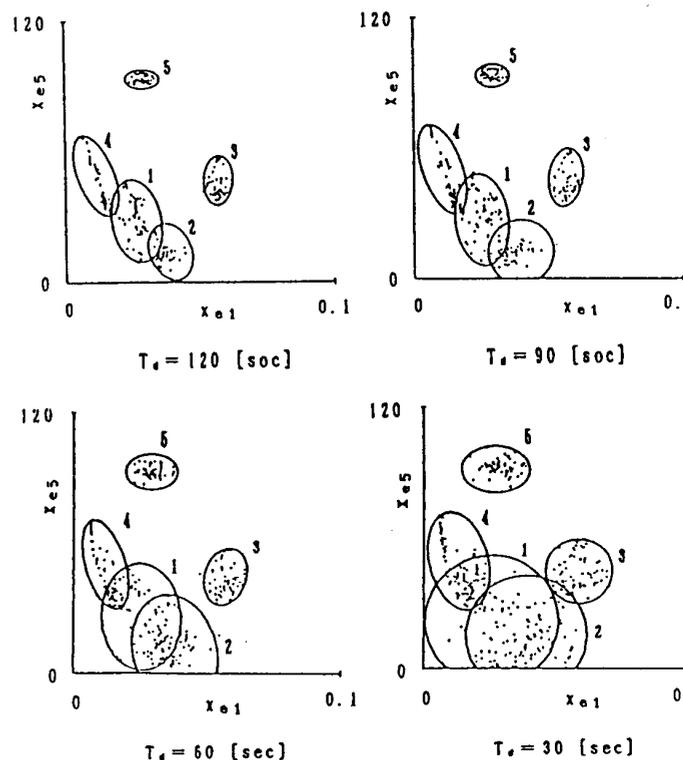


図2 各サンプリング時刻において得られた特徴抽出変数値 $x_{e1}$ ,  $x_{e5}$ の2次元座標表示

ここに、 $x_{e1}$ は、重要な情報である車軸トルクがエンジンの流入空気量と回転数にギヤ位置情報を加えれば近似的に得られる<sup>(5)</sup>ことに着目し、ギヤ位置のデータをも加えて作成したものである。 $x_{e3}$ と $x_{e4}$ については共に車両停止時間を考慮に入れないも

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、環境が五つのうちのどれかを高精度で特定できるものと考えられる。しかし、 $T_s=60, 30$ [秒]と短くなるにつれて各環境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、環境の識別は困難になる。以上から、 $T_s$ の値として90と120を設定する。

### 3.2 環境認識アルゴリズム

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環境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<sup>(6)</sup>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。

#### 3.2.1 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7次元ベクトル $x_e$ を定義する。

$$x_e = (x_{e,1} \ x_{e,2} \ \dots \ x_{e,7}) \quad (1)$$

予め得られている十分長い環境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

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

と表す。なお、以下、環境が特に市街(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、環境未知の入力ベクトル  $x_e=x$  が与えられたとき、 $x$  と、各環境  $e$  に対する  $x_e^*$  とのマハラノビス汎距離  $D(x, x_e^*)$  を求め、それが最小となる環境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。

$$D(x, x_e^*) = \sqrt{(x - x_e^*) \Sigma^{-1} (x - x_e^*)^T} \quad (T: \text{転置}) \quad (3)$$

ここに、重み付け行列  $\Sigma^{-1}$  の逆行列  $\Sigma$  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

$$\sqrt{\frac{1}{N_e} \sum_{n=1}^{N_e} [x_{e,i}(n) - x_{e,i}^*(n)][x_{e,j}(n) - x_{e,j}^*(n)]}$$

なる  $7 \times 7$  行列である。このように、マハラノビス汎距離は、入力ベクトルと環境別重心ベクトルとの単なる2点間の距離だけでなく環境別データ群の広がりも考慮したものとなっている。

#### 3.2.2 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いわゆる IF-THEN 形式のファジィルールに基づくもので、次のように記述される。

予め得られている十分長い環境別の実走行データによる特徴抽出変数  $x_{e,1}, \dots, x_{e,7}$  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） $f_{e,1}, \dots, f_{e,7}$  を作成しておく。いま、環境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の環境eへの所属の度合い（グレード）を

$$\min_{i \in I_e} f_{e,i}(x_i) = \alpha_e \quad (4)$$

すなわち各成分に対するグレードの論理積で表すこととし、 $\alpha_e$ 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 $I_e$ を各環境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前記走行試験で収集された環境別データに適用した環境認識の結果を示す。まず、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 $x_e^*$ を求めると共に、MS関数  $f_{e,1}, \dots, f_{e,7}$  を作成する。次に、各データの後半部を用いて両アルゴリズムにより環境の認識を行った。その結果を  $T_e = 90$ [秒] と  $T_e = 120$ [秒]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

表1  $T_e = 90$  の場合の提案アルゴリズムによる環境認識率

	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 7.1% 渋滞 → 市街 4.0%	市街 → 渋滞 5.0% 渋滞 → 市街 6.8% 市街 → 降坂 0.1%

表2  $T_e = 120$  の場合の提案アルゴリズムによる環境認識率

	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% 渋滞 → 市街 2.7%	市街 → 渋滞 3.7% 渋滞 → 市街 2.1%

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 $I_i$ については

$$I_1 = \{1, 2, 5, 7\}, I_2 = \{3, 5, 6\}, I_3 = \{1, 3\}, I_4 = \{1, 3, 7\}, \\ I_5 = \{2, 3, 5\}$$

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り違えであるが、渋滞の判断は主観にもよることを考えれば、特に  $T_0=120$  の場合の認識率はかなり高いと言える。

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、これらの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 $I_i$ 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利点があり、実用上は後者の方が有効である。

#### 4. 運転者の意図分析

意図分析と環境認識との大きな違いは、識別対象である運転者の意図が道路環境よりもさら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環境により異なってくる。そのため、意図分析は環境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いて、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環境認識と同様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環境が既に認識されたものとして、その環境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

環境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について環境別に3通りの意図状態のもとで取得したセンサ計測データである。

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、意図が反映され易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ため意図分析に役立つものと考えられる。前記の13のセンサ計測値の中から、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。 $T_0$ については、前章の結果を参考にして、 $T_0=120$ [秒]と設定する。これらをもとに、次のような7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、アクセル開速度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/sec] 以上になったときはON、同じく -10[deg/sec] 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、運転者Aについては意図による明確な有意差が見られたが、同Bについてはそれが見られなかった。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。

#### 4.2 意図分析アルゴリズム

前節の結果に基づいて、環境認識の場合と全く同様に、マハラノビス汎距離とファジィ推論による二つの意図分析アルゴリズムを構築する。前者のアルゴリズムについては、環境ごとに(1)式のベクトル $x_e$ に対応するベクトル $x_i$ を設定した。

これらのアルゴリズムを運転者Aの環境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3の結果が得られた。ここでも、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 $x_i^*$ を求めると共に  $x_{i1}, \dots, x_{i7}$  のヒストグラムの形から必要なMS関数を作成し、データの後半部を用いて分析を行った。環境認識の場合と同様、(4)式の $I_e$ に対応するものとしては、幾つか試みたうち最も結果の良かったものを採用した。表3の意図分析率は表1の環境認識率よりも大分低く、やはり意図分析は環境認識よりも困難であることがわかる。

表3 提案アルゴリズムによる環境別の意図分析率

	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%

表3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、環境認識の場合と同様、ファジィ推論による方が計算量が少ないという運用上の利点がある。

## 5. むすび

本研究では、自動車の運転環境適合制御の実現のために道路環境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。環境認識では、まず、実車走行試験により得られた6種類のセンサ計測データから7種類の適当な特徴抽出変数を作成することにより特徴抽出を行えば環境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  $T_d=120$  の場合には93%以上の高認識率が得られた。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り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共十分高いものである。意図分析では、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、環境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、運転行動から見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、道路環境よりも主観的かつあいまいな意図の分析は困難で、しかもその度合いは運転者によって異なることが確かめられた。

以上から結論として、意図分析アルゴリズムはまだ改善の余地あるいは必要性についての検討の余地が残されているが、環境認識アルゴリズムはハードウェアが整備されれば実用化が達成できると考えられる。

## 参考文献

- (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)L. Qiao, M. Sato, H. Takeda: "Learning Algorithm of Environmental Recognition in Driving Vehicle", IEEE Trans. Syst., Man, & Cybern., Vol. 25, No. 6, 917/925 (1995)
- (4)高橋, 南: "ファジィ推論による自動車の走行道路認識", ファジィ学誌, 2巻, 3号, 438/443 (平2)
- (5)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
- (6)田中, 脇本:多変量統計解析法, (昭63) 現代数学社