

## 運転操作信号のケプストラム分析に基づく運転者識別

小澤 晃史<sup>†</sup> 西脇 由博<sup>††</sup> 脇田 敏裕<sup>†,†††</sup> 宮島千代美<sup>†</sup> 伊藤 克亘<sup>†</sup>  
武田 一哉<sup>†</sup>

<sup>†</sup> 名古屋大学大学院情報科学研究科 〒464-8601 名古屋市千種区不老町  
<sup>††</sup> 豊田中央研究所 〒480-1192 愛知県愛知郡長久手町大字長湫字横道 41-1  
E-mail: <sup>†</sup>{k-ozawa,nishiwaki}@sp.m.is.nagoya-u.ac.jp, {miyajima,itou,takeda}@is.nagoya-u.ac.jp,  
<sup>††</sup>wakita@mosk.tytlabs.co.jp

あらまし 自動車の運転行動信号を利用した運転者の識別方法について、検討する。アクセルやブレーキの操作量およびその時間変化の同時分布を運転者毎に混合ガウス分布を用いてモデル化し、運転者識別を行う方法を報告する。次に、運転行動信号が運転意図と操作特性との畳み込みで与えられると仮定し、観測された運転行動信号から、ケプストラム分析を用いることで操作特性だけを取り出す方法を提案する。ドライビングシュミュレータを用いて計測した運転行動信号に対して、提案方法を適用した結果、89.6%の運転者識別率が得られ、提案方法の有効性が示された。キーワード 運転行動信号、ドライビングシュミュレータ、個人識別、混合正規分布 (GMM)、ケプストラム分析

## Driver Identification through Cepstrum Analysis of Driving Behavioral Signals

Koji OZAWA<sup>†</sup>, Yoshihiro NISHIWAKI<sup>††</sup>, Toshihiro WAKITA<sup>†,†††</sup>, Chiyomi MIYAJIMA<sup>†</sup>,  
Katsunobu ITOU<sup>†</sup>, and Kazuya TAKEDA<sup>†</sup>

<sup>†</sup> Graduate School of Information Science, Nagoya University,  
Furou-cho, Chikusa-ku, Nagoya, 464-8603 Japan  
<sup>††</sup> Toyota Central R&D Labs., Yokomachi, Nagakute, Aichi, 480-1192 Japan  
E-mail: <sup>†</sup>{k-ozawa,nishiwaki}@sp.m.is.nagoya-u.ac.jp, {miyajima,itou,takeda}@is.nagoya-u.ac.jp,  
<sup>††</sup>wakita@mosk.tytlabs.co.jp

**Abstract** Driving behavioral signals are expected to be used to improve the safety and convenience while driving. For example, the use of driver's characteristics of the way of controlling vehicle speed, keeping headway distance, and hitting the accelerator pedal will allow us to achieve driver recognition for automatic adaptation of vehicle environments. Drowsy driving detection might also be realized by comparing the driving behavior with that of normal driving. In this work, long-term characteristics of the driver's behavior in the relation between the vehicle speed, the headway distance and the accelerator pedal position, and short-term spectral characteristics of the accelerator pedal position are modeled with Gaussian mixture models. We conduct a driver identification experiment and an 89.6% identification rate is obtained.

**Key words** Driver's behavioral signal, Driving simulator, Person identification, Gaussian mixture model (GMM), Cepstral analysis

### 1. ま え が き

道路交通に関連した技術や社会基盤が高度化するに伴い、カーナビ操作や情報検索など複雑な情報や高度なサービスを運転者に提供することが技術的には可能となりつつある。自動車運転の安全性と快適性の両立は重要な課題であり、自動車運転

行動の解析・モデル化の高度化が望まれる。

これまで、運転行動の解析に関するいくつかの研究が報告されている。マクロな交通流を模擬するための自動車の挙動のモデル化に関して、速度と車間距離の関係を表す様々なモデルが提案されている [1] [2] [3]。また、自動車の挙動をカルマンフィルタや隠れマルコフモデル (HMM) などでモデル化し、運

転意図の認識、自動車挙動の予測を行う研究 [4] [5] や、認知科学の観点から運転動作と判断を統合したドライバモデルに関する研究 [6] なども報告されている。しかし（自動車の挙動ではなく）運転者の運転操作を分析・モデル化する研究はほとんど行われていない。

同一の運転意図や交通状況下であっても、アクセルペダルやブレーキペダルの踏み込み、ステアリングの回転といった自動車運転操作方法は運転者によって異なる。これは、音声言語を用いて同一の意図を伝達する場合でも、状況や話者によって異なる語彙や韻律パタンが使われ、声質も話者によって異なることと対比させることができる。そこで本稿では、自動車の運転行動を観測することで得られる「運転行動信号」に、音声の生成モデルであるソースフィルタモデルを適用することで、「行動の意図」と「振る舞いの個性」を分離することを試みる。すなわち、音声処理で一般的なブラインド逆畳み込み方法であるケプストラム分析を自動車の運転操作信号に適用することで、運転者を高精度に識別できることを示す。

## 2. 運転データの収録

### 2.1 ドライビングシミュレータ

本研究では、ドライビングシミュレータを用いて運転データを収録した。このシミュレータは片側 2 車線の高速道路を模擬しており、道路と側面がモニタに描写される。自車のほかに一台の先行車が描写され、この先行車は若干渋滞した高速道路を走行した自動車の実データを基にシミュレーションされている。運転行動信号として、速度、車間距離、アクセルペダル操作位置、ブレーキペダル操作位置を標本化周波数 100Hz で収録した。またアクセルペダル操作位置とブレーキペダル操作位置は、踏んでいない状態が 0、最も踏み込んだ状態を 10000 として量子化している。

### 2.2 収録

普通自動車免許を取得している 21 歳から 30 歳までの男性 11 名、女性 1 名から運転データを収録した。5 分間の 2 種類のコースを 2 回ずつ走行してもらい、被験者あたり合計 20 分の運転データを収録した。被験者には先行車を追い抜かないように走行するように指示した。収録した運転データの例を図 1 に示す。

## 3. 大局的特徴を用いた運転者個人識別

### 3.1 大局的分布の特徴

大局的な特徴とは、速度、車間距離、アクセルペダル操作位置、ブレーキペダル操作位置、およびそれらの瞬時的な時間変化量の長時間分布である。速度と車間距離の関係は個人によって異なる特徴があると考えられる。すなわち、車間距離をつめて走行する運転者もいれば、低速でも車間距離を大きく取る運転者などもある。このような特徴から、速度と車間距離の同時分布を考えることで、個性を見出すことができるのではないかと考えられる。図 2 に 2 名の運転者の速度と車間距離の分布の例を示す。Driver2 は、Driver1 と同じ速度の時でも、より大きく車間距離をとる傾向がある。




図 1 運転行動信号の例: (a) 速度 [m/s], (b) 車間距離 [m], (c) アクセルペダル操作位置, (d) ブレーキペダル操作位置




図 2 速度と車間距離の同時分布

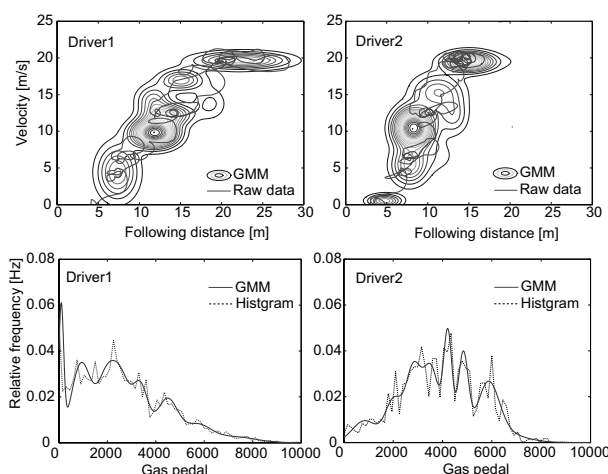


図 3 GMM によるモデル化の例: 上: 速度・車間距離の軌跡, 下: アクセルペダル操作信号の分布

一方、ペダル操作位置に関しては、アクセルペダルを積極的に操作して速度を調節する運転者や、エンブレキを多用してアクセル操作が少ない傾向がある運転者などが考えられる。

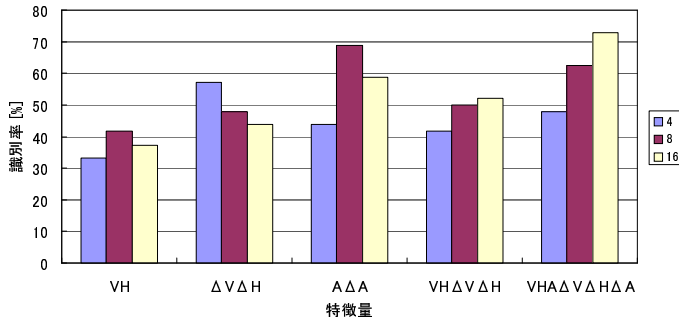


図 4 大局的な特徴を用いた個人識別実験結果

これらは、運転者毎に運転目標<sup>注1)</sup>が異なることを示している。すなわち、大局的特徴とは運転者の運転目標が反映されている特徴と考えられ、運転者毎の運転操作信号の確率密度関数を、混合ガウス分布を用いて表現し、運転者のモデルに用いることができる。

図 3 に 2 名の運転者の運転行動信号を混合ガウス分布によりモデル化した例を示す。このように運転者を混合ガウス分布により表現することで、最大事後確率基準

$$\hat{d} = \arg \max_{1 \leq d \leq D} \sum_{t=1}^T \log p(\mathbf{o}_t | \lambda_d) \quad (1)$$

により運転者の識別が可能である。但し、 $\lambda_i$  は運転者  $i$  に学習された混合ガウス分布のパラメータ（重み、平均ベクトル、分散共分散行列）を、 $\mathbf{o}_t$  は、観測された運転行動信号（ベクトル）を表す。

### 3.2 識別実験

本節の識別実験では、速度  $V$ 、車間距離  $H$ 、アクセルペダル操作位置  $A$ 、およびそれらの時間変化量  $\Delta V, \Delta H, \Delta A$  を特徴量として、それらの頻度分布を GMM でモデル化し個人識別実験を行った。ただし、時間変化量は、速度、車間距離、アクセル操作位置などの元の時刻  $t$  の信号を  $x(t)$  として、次式の回帰係数で与えられる。

$$\Delta x(t) = \frac{\sum_{k=-K}^K kx(t+k)}{\sum_{k=-K}^K k^2} \quad (2)$$

なお、予備実験より、回帰の窓幅を決める定数は  $K = 40(0.4\text{sec})$  とした。また、GMM の混合数を 4, 8, 16 と変化させて、識別率の変化を調べた。学習データの長さは 15 分、評価データの長さは 5 分である。さらに、学習データと評価データ入れ替えてクロスバリデーションテストを行った。

### 3.3 実験結果

図 9 に実験結果を示す。ここで、 $VH$  や  $VH\Delta V\Delta H$  はそれぞれの特徴量の同時分布を意味している。 $VH$  と  $\Delta V\Delta H$  を比較すると、時間変化を特徴量に用いた後の方が識別率が高かった。さらに運転の状態を表す  $V$  や  $H$  を特徴量に用いる場合よりも、アクセルペダル操作位置の信号を用いた方が識別

(注1): より頻度が高い状態ほど、運転者が快適と感じる状態であると考えられる。

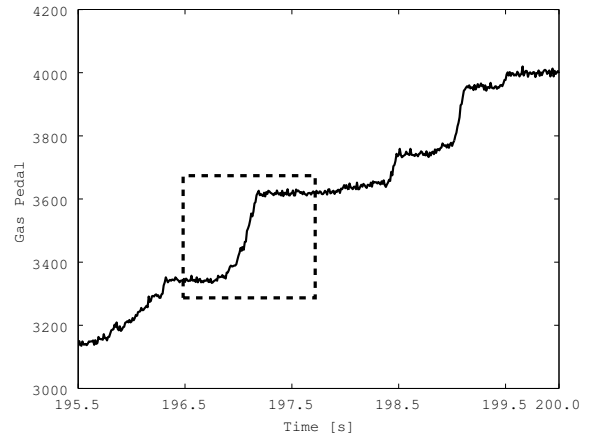


図 5 アクセルペダル操作位置信号の例

率が高かった。よって、大局的な特徴を考えた場合、運転操作の結果として現れる車の状態よりも、運転者の運転操作の特徴が直接現れるアクセルペダル操作位置信号の方により個性が含まれていることが分かる。最も識別率が高かったのは全ての特徴  $VHA\Delta V\Delta H\Delta A$  を用いた場合で 72.9%であった。

## 4. 局所の特徴を用いた運転者個人識別

### 4.1 局所の特徴

運転行動における局所的な特徴とは、運転信号を数秒間に亘って局所的に観測した場合に抽出される特徴である。大局的特徴は運転者の運転に対するルールが反映された特徴であるのに対して、局所の特徴は運転者が無意識の内に行っている操作の特徴、または癖であると言える。本研究では、アクセルペダル操作位置信号に対して、数秒の区間で分析を行った。図 5 にアクセルペダル操作位置信号の例を示す。これを数秒間に亘って見ると、アクセルペダル操作が階段状になっていることが分かる。また、その傾きもほぼ等しいように見える。このペダルの踏み込み方が個人によって異なれば、それをモデル化することで、個性を抽出することができるのではないかと考えられる。

### 4.2 ケプストラム分析

このアクセルペダル操作位置信号の性質は、別の視点からはアクセル操作に対する指令信号が、運転者の振る舞いというシステムを経て出力されたものとみなすことができる。すなわち、アクセル操作に対する指令信号を  $x(t)$ 、運転者の振る舞いの特性のインパルス応答を  $h(t)$  として、アクセルペダル位置信号  $y(t)$  は、指令信号と振る舞い特性との畳み込み、

$$y(t) = x(t) * h(t) \quad (3)$$

により与えられる。

従って、ペダル操作位置信号から運転者の個性を抽出するためには、 $y(t)$  を逆畳み込み (deconvolution) して、 $h(t)$  のみを取り出すことが有効である。前節で議論したように、運転者の振る舞いの特性はアクセル踏み込みの時間変化に対応させることができる。すなわち、 $h(t)$  のスペクトルは緩やかに変化するスペクトル成分に対応することから、音声分析における声道




図 6 アクセル操作の局所モデル

特性の抽出同様、ケプストラム分析を行いその低次項のみを用いることで逆畳み込みを行うことができる。

図 5 はケプストラム分析による特徴抽出の一例をしめしている。図中の破線枠に示すように、アクセルペダル操作位置の局所的な信号が階段状になっていることから図 6 のようなアクセル操作の局所モデルを考える。上の図は、ペダルの踏み込み方(傾き)が異なる 3 つのモデルを示している。そして、下の図は、それぞれのモデルの短時間スペクトルを示している。この例のように、踏み込み方が異なればスペクトルの包絡も異なることから、その違いが(特に低次の)ケプストラムに現れ、個人識別ができるのではないかと考えられる。本手法では、アクセルペダルの操作信号のケプストラムを特徴量として、GMM により運転者をモデル化し、個人識別を行う。

#### 4.3 予備識別実験

予備実験では、ケプストラムを算出するための時間窓(フレーム)の長さ、ケプストラム系列の時間変化を計算する際の時間幅を実験により求める。ケプストラムを算出するためには、時間窓の長さを決める必要がある。この時間窓の長さは、信号をどれだけ時間幅で分析するかを表すものであるため、この幅の設定は重要であると考えられる。また、このケプストラム系列の時間変化( $\Delta$ ケプストラム)を特徴量にすることで、より個人を精度良く識別できることが期待できるので、時間変化窓長についても最適な値を設定する必要がある。

##### 4.3.1 実験条件

まず最適なフレーム長を決めるために、フレーム長を 0.64, 1.28, 2.56 秒と変化させ、識別実験を行った。さらに、ケプストラムの時間変化を計算するためのケプストラム窓長を 0.4, 0.8 1.2, 1.6 秒と変化させて最適な窓長を決めた。ただし、時間変化は式(10)を用いて求めた。なお、その他の分析条件は、識別対象 12 名、学習データ 15 分、評価データ 5 分、フレームシフト 0.1 秒、使用するケプストラムは 0 次から 5 次、GMM の混合数 8, 16, 32、ブラックマン窓で分析を行った。ただし、ブラックマン窓は窓長を  $N$  として以下の式で表される。

##### 4.3.2 実験結果

予備実験の結果を図 7 と図 8 に示す。これらの結果から、フレーム長は 1.28 秒としたときが最も識別率が高く、 $\Delta$ ケプス




図 7 ケプストラム次数 0~5 次, ケプストラム窓長 0.8 秒としてフレーム長を変化させた結果




図 8 ケプストラム次数 0~5 次, フレーム長 1.28 秒としてケプストラム窓長を変化させた結果

表 1 識別実験の分析条件

標準化周波数	100Hz
フレーム長	1.28 sec
フレームシフト	0.1 sec
分析窓	ブラックマン窓, 矩形窓
FFT ケプストラム次数 (0 次から)	1, 2, 4, 6, 8, 16
ケプストラム窓長	0.8 sec
GMM 混合数	8, 16, 32

トラム窓長は 0.8 秒としたときが最も高くなった。これは、フレーム長を 1.28 秒とすることで、アクセルペダルの踏み込みが 1 フレーム内に 0~2 回程度含まれることになり、その結果よく特徴を抽出できたのではないかと考えられる。

#### 4.4 識別実験

予備実験から、フレーム長 1.28 秒、ケプストラム窓長 0.8 秒とし、特徴量に用いるケプストラム次数を変化させて、識別率がどのように変化するか調べた。さらに、時間窓としてブラックマン窓と矩形窓を用いて、窓によってどのように識別率が変わるかを調べた。

実験条件を表 1 に示す。ただし、例えば、FFT ケプストラム次数が 1 の場合、0 次と 1 次のケプストラム係数と、それらの  $\Delta$ ケプストラムを特徴量として、4 次元の GMM でモデル化する。

#### 4.5 実験結果

時間窓としてブラックマン窓を用いた場合の実験結果を図 9




図 9 ブラックマン窓を用いた場合の実験結果




図 10 矩形窓を用いた場合の実験結果

に、矩形窓を用いた場合の実験結果を図 10 に示す。この結果から、使用するケブストラム回数が増えるほど識別率は上昇し、 $c_0 \sim c_5$  または  $c_0 \sim c_7$  あたりが最適であることがわかった。識別率が最もよかったのは、ブラックマン窓を用いた場合 87.5%、矩形窓の場合 89.6%であった。

ここで、特徴的な運転者のスペクトログラムの例を図 11 に示す。これは、一番上の運転者から、ペダルを緩やかに踏み込む傾向がある人、勢いよく踏み込む傾向がある人、一度踏み込むと休止の状態が長く続く傾向がある人の 150 秒間のスペクトログラムの例を示している。この図より、中央の運転者のスペクトルは一番上の運転者のスペクトルよりも高い周波数成分にまでパワーがあることがわかる。また一番下の運転者は休止の状態が多いため、0Hz 付近にパワーが集中することが多いことがわかる。このような違いがケブストラムに現れ、個人の識別ができたのではないかと考えられる。

## 5. まとめ

本研究では、運転行動の大局的な特徴と局所的な特徴を用いて、個人識別実験を行った。その結果、運転行動信号の長時間の分布を、GMM でモデル化し個人識別を行った実験で 72.9%の識別率が得られた。また、アクセルペダル操作位置信号を数秒間で分析し、個人識別を行う実験では 89.2%の識別率が得られた。この結果から、運転者の意思が反映される大局的な特徴よりも、癖に相当する局所的な特徴からのほうが、より個人性を抽出することができるのではないかと考えられる。

本手法は、実車により収集された運転行動信号を用いた運転者識別においても有効であることを確認している。今後は、運

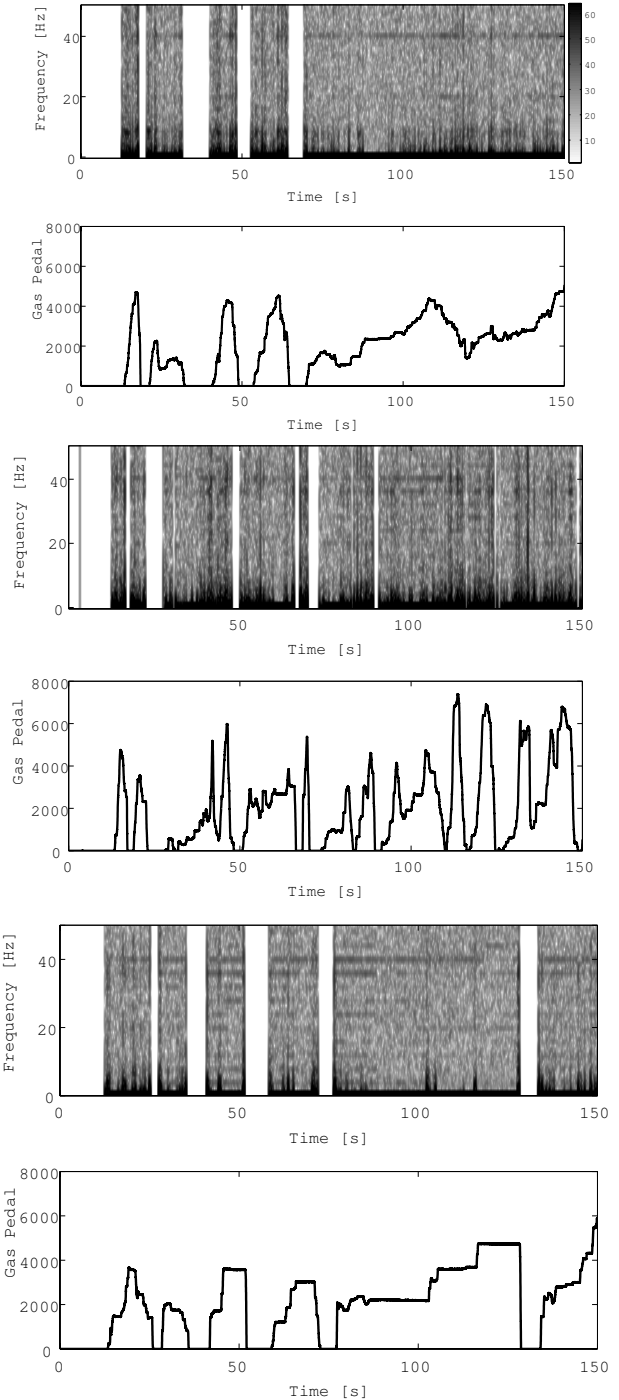


図 11 アクセル操作のスペクトログラムの例

転タイプや運転者の状態と運転行動との対応付けを検討する必要がある。

## 文献

- [1] M. Brackstone, M. McDonald, "Car-following : a historical review," Transformation Research Part F 2 181-196, 1999.
- [2] M. Bando, K. Hasebe, A. Nakayama, A. Shibata, and Y. Sugiyama, "Dynamical model of traffic congestion and numerical simulation," Phys.Rev.E51, pp.1035-1042, 1995.
- [3] 杉山雄規, "交通流の物理", ながれ, 22, pp.95-108, 2003.
- [4] N. Oliver and A.P. Pentland "Driver behavior recognition and prediction in a SmartCar," Proc. of SPIE Aerosense 2000, Enhanced and Synthetic Vision, Apr. 2000.
- [5] A. Pentland and A. Liu "Modeling and prediction of human

- behavior,” *Neural Computation* 11, 229–242, 1999.
- [6] D.D. Salvucci, E.P. Boer and A. Liu, “Toward an integrated model of driver behavior in a cognitive architecture,” *Transportation Research Record*, 2001.
  - [7] K. Igarashi, C. Miyajima, K. Itou, K. Takeda, and F. Itakura, “Biometric identification using driving behavioral signals,” *Proc. ICME 2004*, TP1-2, Jun. 2004.
  - [8] 小澤晃史, 伊藤克亘, 武田一哉, 脇田敏裕, 板倉文忠, “運転行動信号に含まれる個人性に関する検討”, *FIT2004 情報科学技術レターズ* vol.3, pp.247–250, 2004.
  - [9] 古井貞熙, *音声・音響工学*, 近代科学社, 1992.
  - [10] A. Reynolds and C. Rose, “Robust text-independent speaker identification using Gaussian mixture speaker models,” *IEEE Trans. Speech, Signal Processing*, vol.3, no.1, pp. 72–83, Jan. 1995.
  - [11] D.A. Reynolds, “Speaker identification and verification using Gaussian mixture speaker models,” *Speech Communication*, 17, pp. 91–108, 1995.
  - [12] R.O. Duda, P.E. Hart, and D.G. Stork, “*Pattern Classification Second edition*” 2001.