

ケプストラム分析を用いた実収録運転行動信号に含まれる個人性のモデル化 Modeling of Individualities in Driving Behavioral Signals Collected in a Real Vehicle Using Cepstral Analysis

西脇 由博[†] 小澤 晃史[†] 宮島 千代美[†] 伊藤 克亘[†] 武田 一哉[†]
Yoshihiro Nishiwaki Koji Ozawa Chiyomi Miyajima Katsunobu Itou Kazuya Takeda

1. はじめに

自動車保有台数及び、運転免許保有者数は増加し続けており、自動車は日常生活に欠かせないものとなっている。こうした状況の中、近年道路交通の安全化、効率化を目的とした高度道路交通システム(ITS; Intelligent Transport System)の研究が盛んに行われている。例えばETCやカーナビゲーションシステム、また車間距離制御システムといった運転支援システムなどがある。これらのシステムは車両を観測して得られる信号が利用されている。

本研究では、運転者を観測して得られる信号のモデル化について考える。つまり、各々のドライバのアクセルペダル、ブレーキペダルの踏み込み方に着目し、人間の運転行動には各々個人性があるのではないかと考え、この個人性のモデル化を行う。

ここでは、スペクトル特徴の一つであるケプストラムの分布に個人のペダルの踏み込み方の違いが表れることを利用し、ペダル踏力信号に対してケプストラム分析を行い、得られたケプストラム係数を混合ガウスモデル(GMM; Gaussian Mixture Model)[1]によってモデル化した。従来の運転行動信号の分布を直接GMMでモデル化する手法[2]では、運転者の細かな癖(ペダルの踏み込み方など)が表現できないが、本研究で提案する手法では、運転者によってペダルの踏み込み方を効果的にモデル化できると考えられる。これらの2つのモデル化法を運転者識別実験で比較・評価を行った。

2. 運転行動信号

自動車走行する際に観測される走行観測信号を以下に示す。

走行観測信号

- 運転行動信号(ペダル操作、ステアリング操作、…)
- 車両状態信号(速度、加速度、エンジン回転数、…)
- 車両位置信号(車間距離、レーン内横方向位置、…)

上記の走行観測信号は、以下のように利用することが考えられる。

運転支援・危険回避支援への応用

- 運転者認識(誰が運転しているか)
- 運転タイプ認識(せっかち、下手、…)
- 運転状態認識(居眠り、飲酒、…)
- 運転行動認識(追い越し、右左折、…)

[†]名古屋大学大学院情報科学研究所

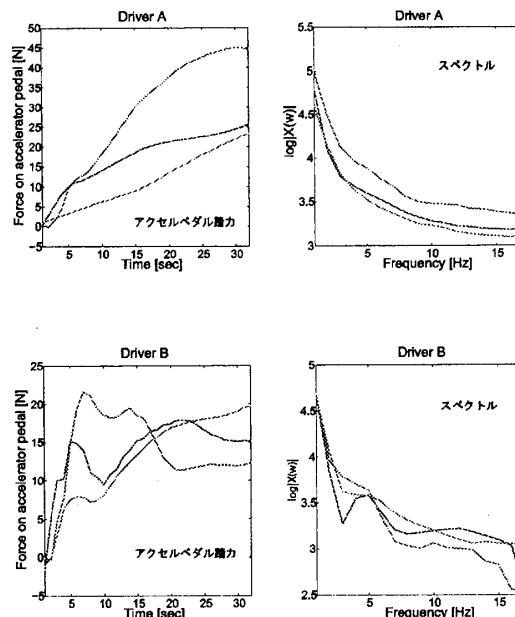


図1: アクセルペダル踏力信号(左図)とそのスペクトル(右図)(上: 運転者A; 下: 運転者B)

走行観測信号を用いて運転者認識や運転タイプ認識を行い、個人の特性に応じた運転支援を行うことや、運転状態認識や運転行動認識を行うことで、危険回避支援を行うことが考えられる。

本研究では、運転行動信号中のペダル操作に着目し、アクセルやブレーキのペダル操作信号のモデル化を行う。

3. ペダルの踏み込み方に着目した特徴抽出

3.1 運転者によるスペクトルの概形の違い

本研究では運転者によるペダル操作信号のスペクトルの概形の違いに着目する。例えば図1(上)の運転者は、アクセルペダルを徐々に踏み込んでいく傾向にあるが、図1(下)の運転者は、一度踏み込んでからペダル踏力を少し緩め、また踏み込んでいくといった傾向にある。図1から分かるように、同一の運転者ではスペクトルの概形が類似し、異なる運転者間ではスペクトルの概形が異なる。そこで本研究では、スペクトルの概形の違いをケプストラムを用いてモデル化することを考える。

3.2 ケプストラムによる特徴抽出

ケプストラムは波形の短時間スペクトルの対数の逆変換として定義される[3]。本研究では、運転行動信号 $x(n)$ から図2のようにしてケプストラム係数 $\{c_m\}$ を算

出した。

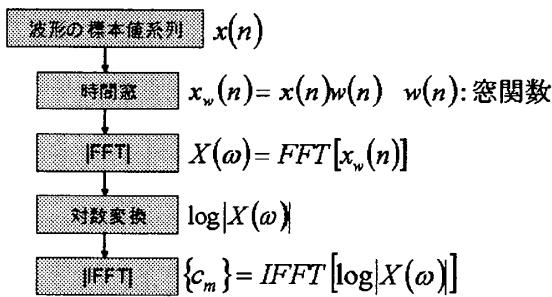


図 2: ケプストラム分析の手順

4. 混合ガウスモデル

4.1 混合ガウスモデルによるモデル化

本研究では、各運転者のケプストラムの分布を混合ガウスモデル(GMM; Gaussian Mixture Model)で表現する。GMM とは有限個のガウス分布の線形結合により表現されるモデルで、 M 個のガウス分布それぞれの混合重み w_m 、平均ベクトル μ_m 、共分散行列 Σ_m により表現できる。

モデル (λ) に観測系列 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$ が与えられたときの尤度は次式で定義される。

$$P(\mathbf{X}|\lambda) = \prod_{t=1}^T \sum_{m=1}^M w_m \mathcal{N}_m(\mathbf{x}|\mu_m, \Sigma_m) \quad (1)$$

ここで、 \mathbf{x} は D 次元のベクトルで、 w_m は m 番目の混合要素の混合重みで次式を満たす。

$$\sum_{m=1}^M w_m = 1 \quad (2)$$

また、 \mathcal{N}_m は、多次元ガウス分布で次式で表される。

$$\begin{aligned} \mathcal{N}_m(\mathbf{x}|\mu_m, \Sigma_m) &= \frac{1}{(2\pi)^{D/2} |\Sigma_m|^{1/2}} \\ &\cdot \exp \left\{ -\frac{1}{2} (\mathbf{x} - \mu_m)' \Sigma_m^{-1} (\mathbf{x} - \mu_m) \right\} \end{aligned} \quad (3)$$

但し、本実験では Σ_m を対角行列とした。また、モデル λ のパラメータは学習データから EM(Expectation Maximization) アルゴリズムを用いて推定した。

4.2 EM アルゴリズム

ここでは、EM アルゴリズムを用いて GMM を学習する方法について説明する。EM アルゴリズムでは、各混合要素の混合重み、平均ベクトル、共分散行列のパラメータを推定するために、以下の手続きを繰り返す。

学習ベクトル系列 $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_T)$ が与えられた場合、 \mathbf{x}_t が m 番目の混合分布に従う確率を

$$q(m|\mathbf{x}_t, \lambda) = \frac{w_m \mathcal{N}_m(\mathbf{x}_t|\mu_m, \Sigma_m)}{\sum_{i=1}^M w_i \mathcal{N}_i(\mathbf{x}_t|\mu_i, \Sigma_i)} \quad (4)$$

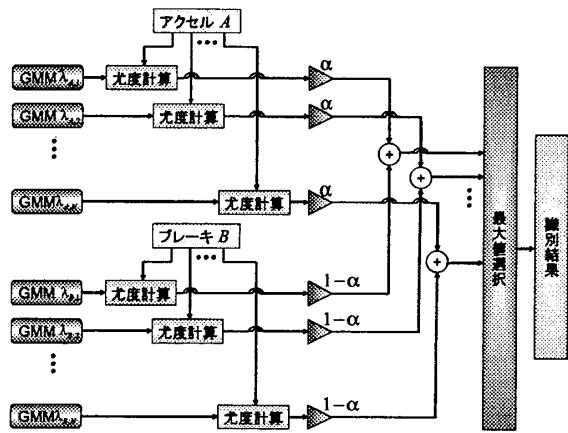


図 3: 運転者識別の流れ

とし、これを用いて各パラメータを更新する。まず、更新後の混合重み \tilde{w}_m は

$$\tilde{w}_m = \frac{1}{T} \sum_{t=1}^T q(m|\mathbf{x}_t, \lambda) \quad (5)$$

となり、更新後の平均ベクトル $\tilde{\mu}_m$ は

$$\tilde{\mu}_m = \frac{1}{T \tilde{w}_m} \sum_{t=1}^T q(m|\mathbf{x}_t, \lambda) \mathbf{x}_t \quad (6)$$

となる。また共分散行列の更新式は

$$\tilde{\Sigma}_m = \frac{1}{T \tilde{w}_m} \sum_{t=1}^T q(m|\mathbf{x}_t, \lambda) (\mathbf{x}_t - \tilde{\mu}_m) (\mathbf{x}_t - \tilde{\mu}_m)' \quad (7)$$

となる。

更新されたパラメータに対し、再び式 (4) を計算し、式 (5)～(7) を用いて各パラメータを更新する。この更新を繰り返すことにより、式 (1) で計算されるモデルの学習データに対する対数尤度が増加していく。この対数尤度の変化量がある閾値以下になるまで更新を繰り返す。

5. 運転者識別システム

本研究では、次式のようにアクセルペダル踏力とブレーキペダル踏力の尤度に重み付けしたスコアが最大となる運転者 k^* を識別結果とする。図 3 に運転者識別の流れを示す。

$$\begin{aligned} k^* = \arg \max_k & \{ \alpha P(A|\lambda_{A,k}) \\ & + (1-\alpha) P(B|\lambda_{B,k}) \}, \quad 0 \leq \alpha \leq 1 \end{aligned} \quad (8)$$

ここで A, B はアクセルペダル踏力とブレーキペダル踏力のケプストラム系列、 $\lambda_{A,k}$, $\lambda_{B,k}$ はそれぞれ k 番目の運転者のモデル、 α はアクセルペダルの重みを示す。

6. 自動車運転データ

本研究で使用した運転行動データは、名古屋大学統合音響情報研究拠点(CIAIR)においてデータ収録用に特

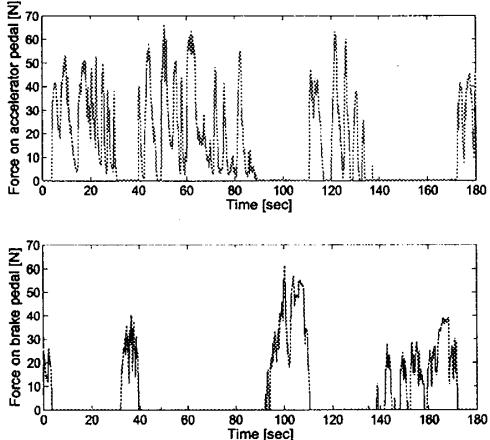


図4: 運転行動信号の例(上: アクセルペダル踏力; 下: ブレーキペダル踏力)

別に設計された実験車(トヨタ・ハイエースレジアス)を用いて、市街地を走行した際に収録されたデータである。運転行動信号としては、アクセルペダル踏力、ブレーキペダル踏力、エンジン回転数、自動車速度、ハンドル角がある。なお、収録は1kHzサンプリングで行われたが、本研究では100Hzにダウンサンプリングしたデータを用いた。本研究では個人性の現れやすいアクセルペダル踏力とブレーキペダル踏力に着目した。図4にその一部を示す。

7. 個人識別実験

7.1 実験方法

個人識別実験ではアクセルペダルの尤度とブレーキペダルの尤度に重みをつけて尤度の算出し、重みを変化させたときの識別率を調査した。実験条件を表1に示す。運転行動信号は運転時間が6分以上の276名とし、学習用データ3分、評価用データ3分とした。GMMにより運転行動信号のケプストラム分布及び△ケプストラム分布をモデル化し、識別を行う。ただし、時間変化を求める際は以下のように回帰係数を求めた。

$$\Delta x(t) = \frac{\sum_{k=-K}^K kx(t+k)}{\sum_{k=-K}^K k^2} \quad (9)$$

ここで、 $x(t)$ は元の信号、 K は時間変化を求める際の時間窓幅を決めるもので、本実験では $2K = 800\text{ms}$ としている。なお、フレーム長、ケプストラム係数、アクセルペダルの重みは予備実験において識別率が良かったものを採用している。また、運転信号の分布をモデル化する従来手法との比較を行った。なお、運転信号の分布を図5にケプストラム係数の0次の分布を図6に示す。ケプストラムの分布は15次まで用いているため信号の分布に比べより多くの特徴が得られていると考えられる。

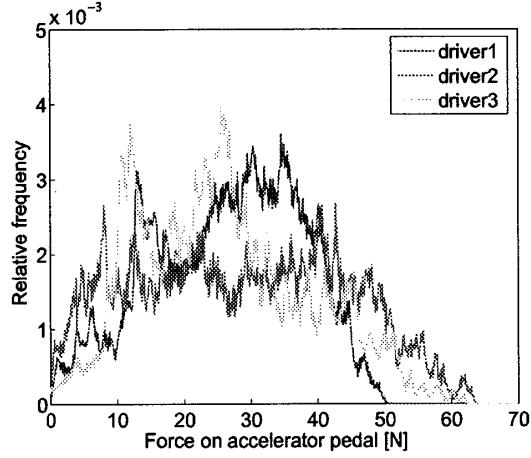


図5: 運転信号の分布

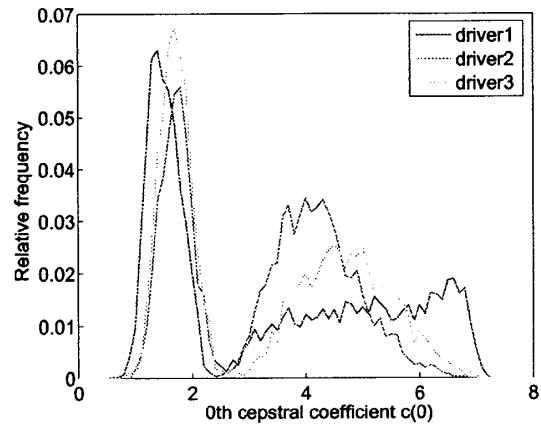


図6: ケプストラム係数の分布(0次)

7.2 実験結果

アクセルペダルに対して重みを変化させた場合の識別結果を図7に示す。ケプストラムの分布をモデル化する手法はアクセルペダル踏力の重みが0.76のときが最も識別率がよく76.8%であった。アクセルペダルの重みが大きいのは、アクセルはブレーキに比べ踏み込む回数が多いいために運転者の特徴が現れやすいためだと考えられる。

また、信号の分布をモデル化する従来手法とケプストラムの分布をモデル化する手法の識別率を比較した結果を図8に示す。運転信号の分布を直接モデル化する手法はアクセルペダル踏力の重みが0.8のときが最も識別率が良く47.5%であった。図8からどの特徴量においても信号の分布をモデル化する手法よりケプストラムの分布をモデル化する手法の方が識別率が高いことが分かる。したがって、運転信号の分布をモデル化する手法よりケプストラムの分布をモデル化する手法の方が個人をよくモデル化できていることがわかる。また、ケプストラムの分布をモデル化する手法では、ペダルの踏み込みの違いなどがモデル化できている。

また、我々はドライビングシミュレータを用いて同様の実験を行ったが、シミュレータについても同様の結果が得られている[1]。

表 1: 実験条件

被験者数	276名
学習用データ, 評価用データ	各3分
標準化周波数	100Hz
フレーム長	0.32 sec
フレームシフト	0.1 sec
分析窓	矩形窓
GMM 混合数	8, 16, 32
FFT ケプストラム係数	c0~c15
△ケプストラム窓長	0.8 sec
アクセルペダルの重み α	0~1

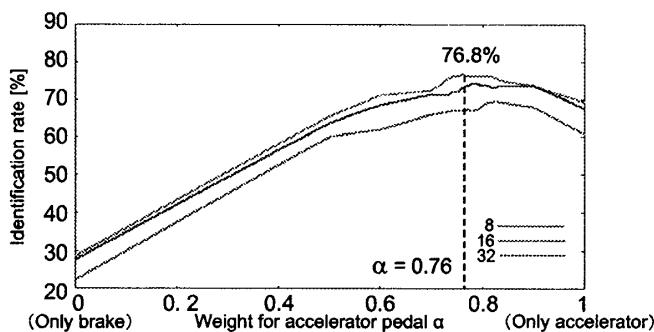


図 7: アクセルペダルの重みと識別率の関係

7.3 評価用データ長が識別率に与える影響

評価用データ長を1分, 1.5分, 3分と変化させ, 識別率の変化について調査した。図9にその結果を示す。評価用データ長が1分の場合, 59.5%まで識別率が低下しているが, データ長が短い場合においても, ケプストラムの分布をモデル化する手法の方が信号の分布をモデル化する手法よりも識別率が高いことが分かる。

8. まとめ

本研究では, 運転行動信号に含まれる個人性のモデル化について検討した。同一の運転者ではペダル踏力信号のスペクトルの概形が類似し, 異なる運転者間では違があるということを利用して, ケプストラムを用いてモデル化を行った。運転者識別実験の結果, ケプストラムによる手法の方が運転信号の分布をモデル化する手法よりも個人性をよく表現できていることが示された。

今後の課題としては, 今回は比較的短い時間(0.32秒)の特徴を用いたが, 運転信号にはペダルを踏み込んでから離すまでといった長時間の特徴も含まれると考えられるため, 長時間の特徴を用いたモデル化も行う予定である。また, 隠れマルコフモデル(HMM)などの時間情報を用いたモデル化についても検討する。さらに今回の運転者モデルを運転タイプ(せつかち, 上手, 下手など)にクラスタリングすることで運転タイプ認識を行うことや, 今回の信号処理手法を用いて運転行動認識[4][5]などをを行うことも予定している。

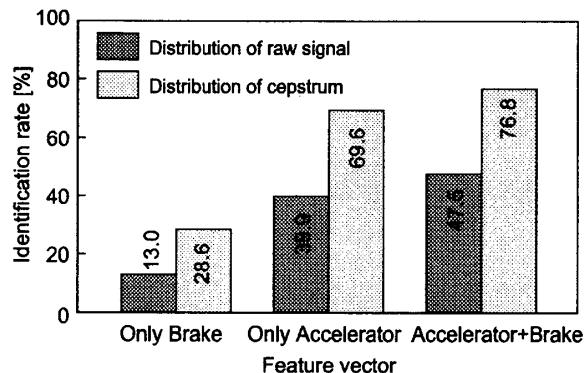


図 8: 従来手法と本手法の識別率の比較

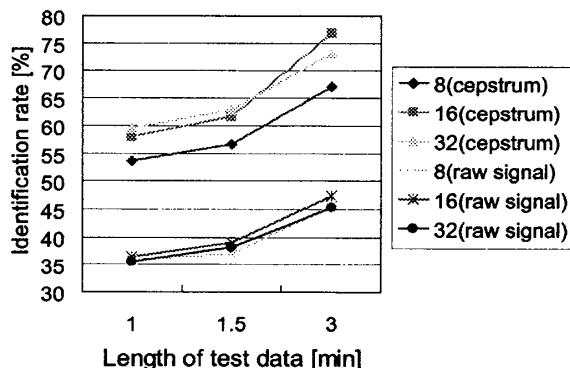


図 9: 評価用データ長と識別率の関係

参考文献

- [1] 小澤晃史, 臨田敏裕, 宮島千代美, 伊藤克亘, 武田一哉, “運転行動信号に含まれる個人性のモデル化,”信学技報, Vol. 104, No. 581, HCS2004-40, HIP2004-85, pp17-22, 2005.
- [2] K. Igarashi, C. Miyajima, K. Itou, K. Takeda, F. Itakura, and H. Abut, “Biometric Identification Using Driving Behavioral Signals,” Proc. ICME 2004, TP1-2, June 2004.
- [3] A. Oppenheim and R. Schafer, “Homomorphic analysis of speech,” IEEE Trans. Audio Electroacoust., vol. AU-16, pp. 221-226, June 1968.
- [4] A. Pentland and A. Liu, “Modeling and Prediction of Human Behavior,” Neural Computation 11, pp.229-242, 1999.
- [5] N. Oliver and A. P. Pentland, “Driver Behavior Recognition and Prediction in a SmartCar,” Proc. SPIE AeroSense 2000.