

# センサデータに基づく運転者挙動の個別性分析とモデル化の検討

Analysis of Individual Driving Behaviors Based on Sensor Data and its Application to Modeling

金月 寛彰

Hiroaki KINGETSU

服部 宏充

Hiromitsu HATTORI

京都大学大学院 情報学研究科

Graduate School of Informatics, Kyoto University

For the sophistication of Multiagent-based traffic simulations, we have tried to construct a behavior model of an agent which can simulate diverse driving behaviors. In this paper, we show an approach to driving behavior modeling with accelerometers. The challenge is to catch the individuality in driving a vehicle of each human driver by measuring and analyzing the data of humans' driving behaviors. The contribution of this paper is to provide knowledge which is useful to construct practical driving behavior models for agents used in traffic simulations.

## 1. はじめに

交通は現代社会に不可欠な社会システムであるが、複雑多様な社会現象が観測できることから研究者の興味を集め、これまで多くのシミュレーション研究が行われてきた [Halle 05, 交通 04]. 従来、交通流は、流体モデルのような個を区別しないモデルに基づいて表現されていた。近年では、個々の車両を区別するミクロレベルのモデルを用いて交通を表現するアプローチへと研究の潮流は変化してきている。マルチエージェントシミュレーション (以下 MASim と記す) に基づいて交通流の模擬を試みる研究はそのような研究の流れに位置づけることができる [藤井 11]. MASim に基づく交通シミュレーションにおいて、モデルの詳細度に関しては異なるアプローチが考えられる。ひとつは表現レベルの車両の区別に留めるものである [Balmer 04]. このアプローチでは、車流を、個々の車両の動きのボトムアップな集積から表現することが試みられるのだが、各車両の行動メカニズムは一様である。それに対して、機能レベルで車両を区別する、すなわち行動メカニズムに関する個別性を考慮するアプローチが考えられる。実世界の交通を、異種異質な運転者による運転行動の集積から生み出される現象と捉えるのは、自然な解釈と考える。そこで筆者らは、実世界の交通流を模擬するために、個別性を備えた運転行動の計算モデル化に関連する研究を行った [Hattori 11].

運転行動モデルを構築するためには、個々の運転者の個性ある行動をどのように捉えるかが課題となる。具体的には、車両挙動レベルの特徴で表現する、運転操作に関する意思決定の傾向を説明する、または運転操作の挙動から特徴を抽出するなど、様々なアプローチが考えられる。筆者らは、特定環境下での人間の運転操作挙動に基づいた行動モデリングについて検討をしてきた。これは、ある時点で観測される運転行動 (車両挙動) は、それ以前に行われた準備動作や認知情報によって引き起こされるものであり、それらをモデルに取り込むためには、人間の身体的な挙動の分析を基に計算モデルの構築を試みる必要があると考えるからである。

本論文で述べるのは、センシング技術の援用によって精緻に計測した人間の運転操作の挙動データに基づく、運転挙動にみられる個別性の分析、ならびに分析結果に基づく計算モデル化

連絡先: 金月 寛彰, 京都大学大学院情報学研究科, 〒 606-8501 京都府京都市左京区吉田本町, 075-753-5396, kingetsu@ai.soc.i.kyoto-u.ac.jp

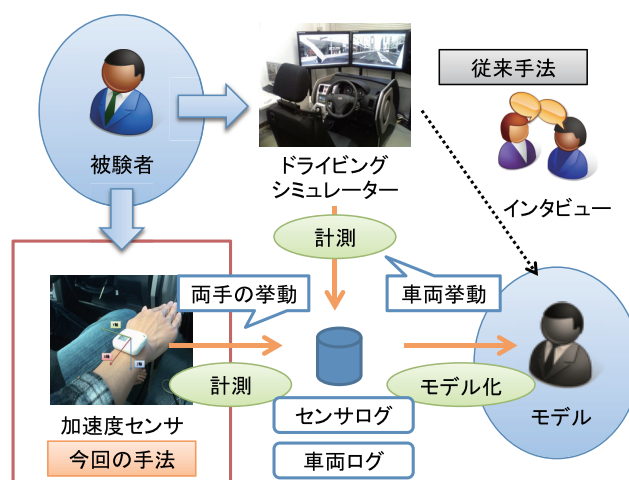


図 1: 人間の運転行動分析の手続き

への適用の検討・考察である。具体的なデータを裏付けとして運転者間の類似・相違を明らかにし、さらにどのような行動がそれらの運転者間の関係を導くかについて議論する。

## 2. 運転行動の分析

### 2.1 分析環境

図 1 に、本論文における運転行動の分析環境と分析プロセスの概要を示す。本論文では、図にあるドライビングシミュレータを運転行動の計測環境として利用する。本シミュレータを利用し、被験者は実車と同様のシートに座り、仮定の走行環境を走行することができる。ドライビングシミュレータを用いた行動計測には、計測データにはリアリティが欠けるデメリットがある一方、計測環境の統制が容易であり、かつセンサデータへのノイズの混入を抑えやすいというメリットがある。

被験者は、図に示す小型の加速度センサを両手首に装着し、複数回の右左折を伴う 22km の走行環境上を運転する。その結果、ハンドル操作を含む手の挙動に関するセンサログ、および車両挙動データ (e.g., 走行速度, 進行方向) を獲得でき、運転操作の分析、ならびに計算モデル化に活用することができる。

## 2.2 関連研究

2.1 で述べたような、人間の運転挙動や車両の挙動のデータを用いた分析がこれまでに行われている。小澤らは、走行速度、車間距離、アクセルペダル操作信号、およびブレーキペダル操作などの運転行動信号を用いた個人識別を試みている [小澤 07]。この論文では、仮想走行環境上で渋滞を造り出し、一定の車間距離を開けて前の車の追従走行をするという条件下で運転行動信号を取得している。取得データを基に直接混合正規分布によるモデル化を行う手法を提案しており、89.6%の識別精度が得られる事を示している。本関連研究では、仮想走行環境から得たデータから個の識別が可能である事を示しているが、その主眼は識別可能性にあり、個の性質まで言及するものではない。

多田らは、両手首につけた加速度センサを用いて初心者と熟練者の運転動作を計測し、模範運転からの逸脱検出を行っている。模範運転者から得たセンシングデータを教師としてサポートベクタマシン (SVM) を適用し、逸脱検出を適合率 71.1%、再現率 73.9%の精度で可能である事を実験的に示している [多田 08]。本関連研究は、加速度センサによる運転者挙動の直接的な計測による分析手法の提案で本論文の内容とも関係が深いものだが、行われているのは“模範的な運転”と“潜在的事故誘引動作を含む危険な運転”といった、運転の性質を表すクラス分類・検出であり、個別性にフォーカスしたものではない。

このように、関連研究では、運転者毎に行動の差異が存在する事が示されている一方で、運転者が個々に持つ運転操作に関する特徴について十分に考察が行われているわけではない。

## 3. 特徴的運転行動分析のアプローチ

本論文では、2. で述べた通り、統制が容易な仮想走行環境を用意し、運転者の挙動データの計測を行い、人間の運転行動における個別性に関する分析・考察をする。

車両の運転において計測すべき対象は複数考えることができるが、分析の簡単のため、本論文では運転操作時のハンドル捌きを対象を絞り、特徴的な挙動の検出と分類を試みる。ところで、本論文で示すのは、加速度センサデータからの運転行動の個別性分析であるが、加速度センサが捉える運転操作挙動において、どのように特徴が現れるかは明らかではなく、分類されるクラスも未知である。このような先見の知識の不足から、関連研究にあるような教師あり学習によるアプローチが適用しにくい。そこで、教師無し学習を行い、計算結果の視覚化に適した自己組織化マップ (以下、SOM と記す) [Kohonen 00] を用いた分析を行う。SOM を用いた研究として中山ら [中山 11] の試みがあり、加速度センサーのデータから個人の行動の特徴を SOM によって分析し、ジェスチャー認証に利用可能であることを主張している。よって、個別性の分析に対して、SOM が効果的に適用できる事が期待できる。




図 2: 加速度センサデータの分析プロセス

	第1主成分	第2主成分	第3主成分	...	第9主成分	第10主成分
Standard deviation	2.59E+04	1.39E+04	9.03E+03	...	2.98E+03	2.64E+03
Proportion of Variance	5.63E-01	1.63E-01	6.83E-02	...	7.44E-03	5.84E-03
Cumulative Proportion	5.63E-01	7.26E-01	7.94E-01	...	8.99E-01	9.05E-01

表 1: 主成分分析の結果

今回の実験での取得したセンサデータから分析までのプロセスを図 2 に示す。被験者が装着した加速度センサから三軸の波形データが得られる。加速度データには重力加速度が含まれるため、センサの向きによる影響を受け、三軸成分に分けた解析が難しい。そこで本論文では、三軸成分のノルムを算出し、分析を進める事とした。ノルムは時分割した各々のデータに関して計算されるため、出力される総データ数が大きくなる。そこで次に、算出したノルムを主成分分析 (PCA) にかけて、複数の独立した特徴要素を算出する。その結果を基に学習を行い SOM としての出力を得る。

SOM は多次元の入力データを視覚可能な次元空間にマッピングするものである。より具体的には、教師なしの学習によってデータのクラスタリングを行い、その結果が可視化される。出力結果では、二つのノード間の距離が近ければ、それらのノードは類似していると見せる。

ただし、基本的な SOM は学習結果が、利用する学習データの影響を受けるという欠点がある。これは、マップの境界付近のノードは、中央付近のノードに比して近傍のノード数が少なくなるためである。そこで、トラス型の SOM を用いて、近傍ノード数の偏りを避け、正確なマップの生成を行う。

## 4. 実験と考察

### 4.1 設定

仮想走行環境において、運転経験の異なる被験者 22 名に関して各々 18 試行の右折運転を計測した。右折時のハンドル捌きについて、個人的特徴の分析と分類を行うのが本実験の目的である。本実験では、2.1 で述べたとおり、両手首に装着した加速度センサで被験者の挙動を計測し、事後検証用としてビデオカメラによる撮影を行った。また、ハンドルの操作量、ならびに被験者に操作による車両の挙動をシミュレーションソフトウェアが記録を行った。

加速度センサは、被験者の動きを阻害しない無線加速度センサを用いた。加速度センサの装着位置を両手首としたのは、[多田 08] において最も良い精度を示すことが報告されているからである。333Hz でサンプリングされた 5000 個までの三軸加速度データを加速度センサから取得する。取得データから算出したノルムを PCA にかけた結果を表 1 に示す。累積寄与率が 90% となる主成分までを採用し、その主成分スコアを特徴量と定義した。得られた特徴量を入力とし、マップサイズ 100x100、学習係数 0.01、近傍半径 30、および学習回数 100,000 のパラメータで学習を行った。

### 4.2 結果

全被験者からの計測データを基にトラス型 SOM で生成したマップを図 3 に示す。被験者の各試行に対して、被験者名と実験試行回数の組合せで ID を付与し、ID をラベルとしたノードがマッピングされている。例えば、C10 ならば被験者 C の 10 回目の試行結果に基づくノードを示している。図中の濃淡によってクラスタリングの結果を視認できる。すなわち、色の濃い部分はクラスタの境界を意味しており、よってノードの距離に近いほど類似性が高い事を意味するのだが、濃い部分





図 3: 加速度センサーデータに基づく自己組織化マップ



(a) 安定挙動を取る被験者 D (b) 挙動にばらつきが大きい被験者 P

図 4: 運転行動のばらつきの比較


を跨いだノード間では類似性は低くなる。図示する通り、二次元平面上にマッピングされた結果から、被験者の各右折行動は複雑なクラスタに分類される事が確認できる。

## 5. 考察

### 5.1 運転行動の安定性について

運転操作に関する疑問として、被験者行動における一貫性の有無が挙げられる。先述の通り、被験者の各試行結果に関するノードから複数のクラスタが形成されたが、被験者の行動に一貫性があれば、ある被験者に関するノードは同一のクラスタに含まれると予想され、そのような被験者は運転行動に高い安定性があるとみなすことができるだろう。一方、ノードの位置に関する散らばりが大きい被験者は、運転行動に関する安定性が低いものとみなすことができる。

図 4 は、安定性に差異が見られる二人の被験者に関するノードを、生成されたクラスタに重畳表示したものである。被験者 D の試行に関するノードは、ほぼすべてが同一クラスタに含まれ、かつノード間の距離も近い。一方、被験者 P の試行に関するノードは複数のクラスタに散らばっており、かつ同一クラスタ内のノード間距離も大きくなっている。このように、視覚的に運転操作傾向の相違を認識することができ、運転の安定性の点から個性を見い出せる可能性を示唆している。なお、実際に、撮影したビデオカメラ記録から確認したところ、被験



(a) 安定挙動を取る被験者 F (b) 被験者 D や被験者 F と類似する行動を取っているが挙動にばらつきがある被験者 C

図 5: 安定挙動を取る被験者間の比較

A	B	C	D	E	F	G	H	I	J	K
16176	23168	21455	2366	28048	4483	8378	26816	19025	26055	27181
L	M	N	O	P	Q	R	S	T	U	V
21191	16553	20562	21549	29898	22360	19459	20957	21564	24118	26563

表 2: ノード間の平均ユークリッド距離

者 D はほぼ同一の運転挙動を示しており、被験者 P は不安定な運転挙動を示している事が確認できた。

被験者の各試行から得られたノード間のユークリッド距離の平均値を表 2 に示す。値が低いほど行動が安定し、値が高いほど行動にばらつきがある事を意味する。よって、例えば、図 4 における被験者 D は表中でも最も小さい値を極めており、安定した挙動を示している事が確認できる。また、被験者 D に次ぐ安定性を示している被験者 F についてのマップを図 5 に示す。F についても同じようなマップの分布を示しており、全体を通して安定挙動だった被験者 D と、被験者 F は加速度センサーの動きから見ても行動に類似性が見られる。このように、運転行動の安定性に基づく個性の把握、ならびに行動の類似性を判断できる可能性を示した。

### 5.2 主成分に関する考察

図 2 に示した、特徴量抽出ステップに用いたそれぞれの主成分に関して、SOM 上で可視化することにより、何を原因としてクラスタが形成されたかを考察する。主成分の意味づけの解釈には、主成分と加速度センサーログとの相関係数を求めることで得られる因子負荷量を用いた。図 6 は第 1 主成分の最大値を赤色、最小値を青色で表現したものである。第 1 主成分は、右折挙動終了時のハンドルを元の位置に戻すタイミングとの間に、 $-0.8$  の相関値を示した。よって、第一主成分は特徴量の値が低いほど、右折終了時の加速度センサーの値が高いことがわかる。次に、第 2 主成分について、同様に図 7 に表す。第 2 主成分の因子負荷量は右折終了時のハンドルの入り始めに $-0.6$  の相関があった。

以上から、今回の実験において加速度センサーの特徴的動作は主に右折動作の終了時、次に、右折開始時に見られることがわかった。ただし、この結果はハンドルの回し方に依存するだけでなく、右折時の車両速度にも依存していることが考えられる。両方に特徴的動作が見られたが、今回の手法ではそれらの原因を分離することができなかった。

## 6. おわりに

本論文では、MASim における現実的なエージェントの実現のために、加速度センサーデータに基づく運転者挙動の個性化分



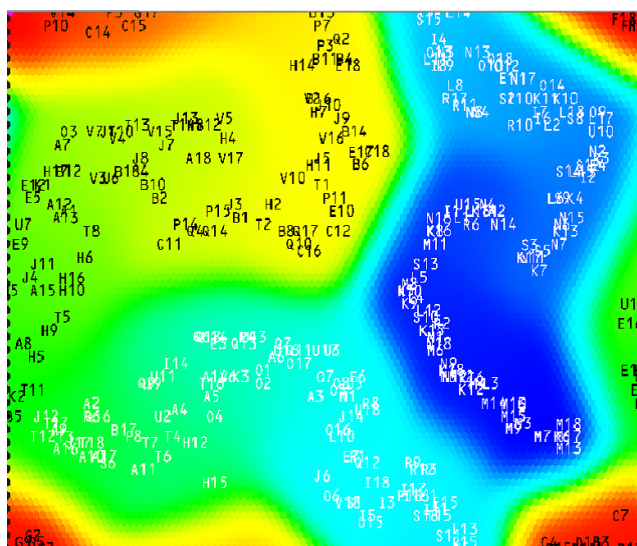


図 6: 第 1 主成分を基にした色分け

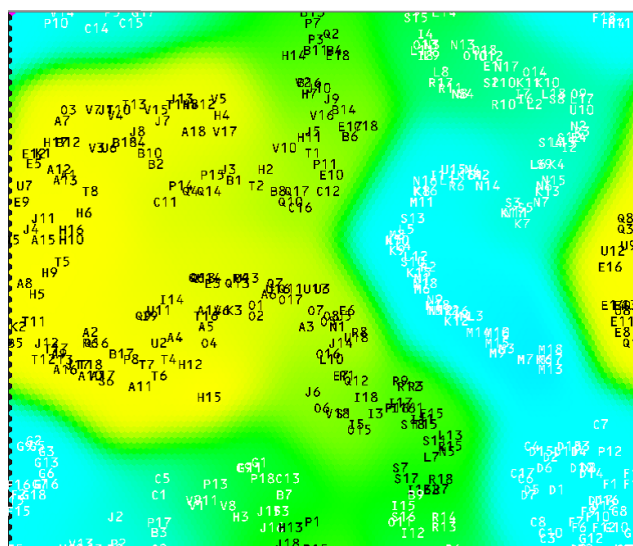


図 7: 第 2 主成分を基にした色分け

析を行った。挙動のばらつきについてユークリッド距離による凝集度だけではなく、SOM を用いることによって視覚的に挙動のばらつき具合と行動の類似性を確認できるようになった。また、挙動のばらつきに関して、運転者間で個別性のある特徴的動作の抽出に一定の成果を示せた。

一部では主観と異なったマッピングも見られたり、より詳細な特徴的動作を抽出するにはハンドル挙動の個別性と車の速度の個別性との分離の必要性があったりしたが、これらはセンサーデータの前処理の方法で解決できると考えられる。詳細なモデル構築の可能性を残した一方で、得られる実験データの不足や、今回は右折動作のみの分析に留まったため、被験者ごとの習熟度や利き手などのパラメータと特徴的行動についての関連性については深く言及することができなかつた。より現実的なエージェントの構築のためには、さらなる検証が求められる。

## 参考文献

- [Balmer 04] Balmer, M., Cetin, N., Nagel, K., and Raney, B.: Towards truly agent-based traffic and mobility simulations, in *Proc. of the 3rd International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS-04)*, pp. 60–67 (2004)
- [Halle 05] Halle, S. and Chaib-draa, B.: A Collaborative Driving System Based on Multiagent Modelling and Simulations, *Journal of Transportation Research Part C: Emerging Technologies*, Vol. 13, No. 4, pp. 320–345 (2005)
- [Hattori 11] Hattori, H., Nakajima, Y., and Ishida, T.: Learning from Humans: Agent Modeling with Individual Human Behaviors, *IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*, Vol. 41, No. 1, pp. 1–9 (2011)
- [Kohonen 00] Kohonen, T.: *Self-Organizing Maps*, Springer (2000)
- [交通 04] 交通工学研究会：交通シミュレーション適用のススメ, 交通工学研究会 (2004)
- [小澤 07] 小澤 晃史, 西脇 由博, 脇田 敏裕, 宮島 千代美, 伊藤 克互, 武田 一哉: スペクトル分析を用いた運転行動信号に含まれる個人性のモデル化, 電子情報通信学会論文誌, Vol. J90-D, No. 4, pp. 1115–1123 (2007)
- [多田 08] 多田 昌裕, 納谷 太, 大村 廉, 岡田 昌也, 野間 春生, 鳥山 朋二, 小暮 潔: 無線加速度センサを用いた運転者行動の計測・解析手法, 電子情報通信学会論文誌, Vol. J91-D, No. 4, pp. 1115–1129 (2008)
- [中山 11] 中山 亮介, 納富 一宏, 斎藤 恵一: 自己組織化マップを用いたジェスチャー認証手法: 複数マップによる分析と評価, バイオメディカル・ファジィ・システム学会誌, Vol. 13, No. 1, pp. 29–34 (2011)
- [藤井 11] 藤井 秀樹, 吉村 忍: 知的マルチエージェント交通流シミュレータ MATES の開発第三報: 多階層歩行者モデルの開発と歩車混合交通シミュレーション, 日本シミュレーション学会論文誌, Vol. 3, No. 3, pp. 70–78 (2011)