

参加型モデリングに基づく運転行動モデル構築手法

服部 宏充[†] 中島 悠[†] 石田 亨[†]

A Methodology of Driving Behavior Modeling based on Participatory Modeling

Hiromitsu HATTORI[†], Yuu NAKAJIMA[†], and Toru ISHIDA[†]

あらまし 近年急速に活発化しているマルチエージェントシミュレーション研究において、エージェントモデリングは核となる技術である。本論文では、応用領域として交通問題に着目し、参加型モデリングに基づいた個別の運転行動モデルの獲得のために、人間の運転行動を説明するための先験的知識を基にモデルを構築するための手法を提案する。運転者横断的な先験的知識の利用を行う本手法によって、個別の運転スタイルが再現できる事を、実験によって明らかにする。

キーワード マルチエージェントシミュレーション, エージェントモデリング, 交通シミュレーション

1. ま え が き

マルチエージェントシミュレーション (Multiagent-based simulation: MABS) が、従来では実験が困難であった、社会、経済、文化など、人間の意思決定が中心となる問題にアプローチする手段として注目されている [1]。MABS の結果は個々のエージェントのミクロレベルの振る舞いに依存するため、ミクロレベルの振る舞いを規定するエージェントモデリングは MABS の核となる技術である。MABS の既存研究には分析型のアプローチが多く、エージェントモデルは分析に適したシンプルなものや、抽象度の高いものとして定義される事が多い [2], [3]。社会システムの創造のための MABS では、新たな制度の開発や検証のために実世界の再現性が求められるため、分析指向の既存研究のようなモデルでは不十分である。現実的なエージェントモデルの実現のために、実世界での人間の行動から学習するのは自然なアプローチである。本論文で筆者らは、人間の行動の計算モデル化を試みる。

人間の行動モデルの構築に対して参加型モデリング [4] は有望な技術である。参加型モデリングの応用により、人間の行動と共に、その動機に関する情報を抽出できる。抽出した情報は人間の行動を説明するための先験的知識として利用できる。個々の人間の行動

系列に対し、蓄積した先験的知識から成る個別の行動モデルを構築する。モデルを構成する知識は、行動系列に含まれる局所的な行動の説明に利用される。

本論文では、具体的な応用領域として交通問題に着目する。人間の運転者は個々の運転スタイルに従って車両を操作すると仮定し、参加型モデリングに基づき、個々の人間の運転行動を再現可能な運転行動モデルの構築を試みる。しかし、車両の運転は、常に変化する環境での即応的な意思決定の連続により行われるため、明示的な知識を得ることが難しい。実際に人間の運転者は、意図的でない運転操作、つまり論理的理由も無く操作を行う事がある。そのような運転操作に関しては、運転者本人からであっても説明のための知識の抽出が難しい。また、運転者のあらゆる操作の知識化を試みるのは、時間的なコストが大きい。この結果、モデル構築に対する知識量の不足という困難が生じる。そこで筆者らは、他の運転者から抽出した知識を補完的に用いる、運転者横断的な先験的知識利用によるモデル構築のアプローチを採る。すなわち、モデル化対象の運転者から抽出した知識だけでなく、他の運転者から抽出した知識も用いて説明を試みる。本論文では、運転者横断的な知識利用によって構築されるハイブリッドな運転行動モデルが、個々の運転スタイルを再現可能であることを実験によって明らかにする。

以下 2. ではモデリングのプロセスを詳述し、3. で提案手法によるモデリングの具体例を示す。4. で獲得モデルの評価を行い、5. で関連研究と比較する。

[†] 京都大学大学院 情報学研究科
Graduate School of Informatics, Kyoto University




図1 本研究で用いたドライビングシミュレータ
Fig. 1 A 3D Virtual Driving Simulator

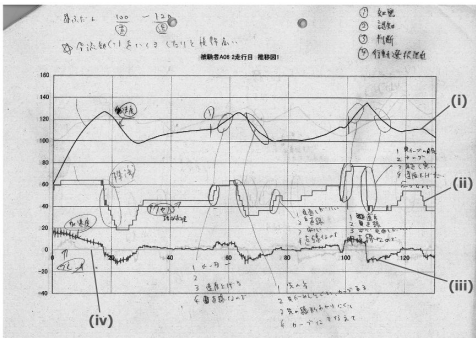


図2 走行ログデータのグラフの例。(i), (ii), (iii), および (iv) は、それぞれ速度、加速度、アクセル使用量、およびブレーキ使用量を表す

Fig. 2 An Example of a Chart made from Log Data

2. 運転行動モデリング

本章では、参加型モデリングに基づいた運転行動モデリングのプロセスを詳述する。参加型モデリングに基づくモデル化の利点は、問題領域における人間の実際の振る舞いを反映する事ができる点にある。

2.1 参加型ドライビングシミュレーションの実施
運転行動モデルを構築するためには、人間による実際の操作データが必要である。交通は常に環境が変動する複雑なシステムであるため、実世界での実験・観察には障害が多く、必要とするデータの収集は困難である。そこで、仮想的な交通環境を提供するドライビングシミュレータを利用する。図1に筆者らが用いたドライビングシミュレータを示す^(注1)。本シミュレータは、実車と同様の運転台と広角のディスプレイを備え、3次元仮想空間上での擬似的な運転環境を提供で

(注1): 本研究では、大阪大学大学院工学研究科飯田研究室のドライビングシミュレータを利用した。

きる。ドライビングシミュレータを利用し、走行速度、加速度、アクセル/ブレーキの使用量に関して、実世界での走行時に近い運転操作データが得られる。図2に獲得した操作データから作成したチャート例を示す。図に示す通り、走行速度、加速度、およびアクセル/ブレーキの使用量の推移に関するデータが得られる。

2.2 特徴的な運転操作の特定

得られた操作データから特徴的な運転操作を特定する。本研究では以下のデータを利用する。

- (1) 時刻 (sec): 走行開始時からの経過時間
- (2) 走行距離 (km): 走行開始地点からの距離
- (3) 速度 (km/h): 車両の速度
- (4) アクセル使用量 (%): アクセルペダルの踏み込み位置。全く踏込んでいない状態を0%とし、最大に踏込んだ状態を100%とする。

図2のグラフ上に円でマークされた部分は、特徴的な操作を認めた箇所を示す。ただし、特徴的な操作の特定は筆者らのみでは難しい。領域の専門家である交通工学者の協力を得て作業を行った。例えば、速度と加速度が、それぞれ5km/h, 5m/s程度変化している点、およびアクセル使用量が10%程度変化している点を確認する、といった作業上有用な知見を得た。

2.3 被験者インタビューによる先験的知識の抽出 シミュレーションの被験者にインタビューを行う。

インタビューの目的は、領域知識として利用する先験的知識を被験者から獲得することである。なお本論文では、先験的知識を人間の特定環境下での操作を説明できる知識と定義し、万人に共通した一般性の高い知識とは考えない。インタビューでは特徴的な操作として特定された箇所を対象に、(1) 注視動機・注視対象、(2) 認知内容、(3) 評価・感情経験、(4) 行動選択・決定理由の4点について質問した。例えば、図2上のグラフの中央の地点に関して以下の回答を得ている。

- (1) 道路の前方
- (2) カーブに接近しつつある
- (3) 道路の先の線形が見えづらい
- (4) カーブに備えるため

インタビュー結果とチャートの分析から、特定の状況下での被験者の運転操作を表す知識(操作ルール)が得られる。得られた操作ルールから、利用困難なものは事前に除去する。例えば、後述の実験では「気分が良ければアクセルを踏む」というルールが得られた。人間の内部状態の観測はできないため、感覚に言及するルールは除去した。

Predicate	Description
Straight(X)	X is a straight road.
Curve(X)	X is a curve.
Uphill(X)	X is an uphill.
Downhill(X)	X is a downhill.
On(X, Y)	Y is driving on X.
InSight(X, Y)	Y can see X.
OverDesiredSpeed(X)	A car X's speed exceeds its desired speed.
UnderDesiredSpeed(X)	A car X' speed is under its desired speed.
OverCurveSpeed(X, Y)	A car Y's speed is too high in a curve X.
SpeedUp(X)	A car X is speeding up.
SlowDown(X)	A car X is slowing down.
Accelerate(X)	A car X is accelerating.
Decelerate(X)	A car X is decelerating.

表 1 観測事象の表現に用いた述語
Table 1 Predicates to represent actions

筆者らは、インタビューによって効果的に知識を抽出するための知見を持たない。そこで交通工学者の提案に基づき、プロトコル分析法に則りインタビューを行った。プロトコル分析法とは、被験者への質疑応答や自然な発話を前提とした対話により、人間の考えや感じた事を抽出・検討する方法である。運転挙動分析に適用した既存研究は、挙動変化に至る意思決定過程を抽出し、データ解釈の根拠が得られた事、異常値の棄却が可能であった事を報告している [5]。よって、分析対象の操作が被験者に強く依存するか、操作に至る意思決定が特殊かを判断するのに適した手法と言える。

2.4 観測事象の記述

ログデータに基づき、観測事象を述語論理で記述する。観測事象とは、シミュレーション中に被験者が観測した事象、およびその時の運転操作を意味する。本論文では、交通工学者との議論を通して運転者の行動に影響を与える可能性があると判定した観測事象、および操作ルールの形式的表現に必要な観測事象を選定した。選定した述語を表 1 に示す。観測事象と操作ルールを統一した記法で形式的に表現することで、モデル構築ステップでの機械的な処理が可能になる。

2.5 先験的知識に基づくモデル構築

2.5.1 用語の定義

本論文では、被験者は各々の視点から観測した周辺環境に基づいて次の操作を決定すると仮定する。 E は被験者が観測した環境を表し、環境を表すリテラルの連言から成る。時刻 t における環境を E_t で表す。運転行動モデル M は、モデル化の対象の被験者によって実行される操作ルール集合 P と、操作ルール間の優先度に関する順序関係 \preceq との対 $\langle P, \preceq \rangle$ で

表される。 P はインタビューから得られた全ての操作ルールの集合 $Rules$ の部分集合である。従って、ある被験者のモデルは、自分以外の被験者から得られたルールを含む可能性がある。 \preceq は、直積集合 $Rules \times Rules$ の部分集合である。 $Rules$ に含まれる各操作ルールを $rule_i (0 \leq i \leq j \leq |Rules|)$ とすると、 $\langle rule_i, rule_j \rangle \in \preceq$ の時、関係は $rule_i \preceq rule_j$ と記述する事もできる。

モデル構築に仮説推論を適用するため、被験者の操作ルールや操作の選択方法など、常に成り立つ知識を領域知識 Σ として定義し、 Σ に含まれる知識を $\sigma_k (0 \leq k \leq |\Sigma|)$ と記述する。一方、各操作ルールが被験者に利用されたか ($rule_i \in P$)、どのルールが優先されるか ($rule_i \preceq rule_j$) といった、常に成り立つとは限らず、かつ他のルールと矛盾する可能性のある知識は仮説とし、仮説集合を H と記述する。最終的に仮説推論により導かれた解 h から、被験者の運転行動モデル $\langle P, \preceq \rangle$ を構築する。なお、 h は H の部分集合である。操作選択に関する知識を以下に定義する。

定義 1 (操作の選択: σ_1)

$$(\exists rule_i (rule_i \in P \wedge rule_i = \max_{\preceq} \{rule | \text{Applicable}(rule, E_t)\})) \Rightarrow \text{Do}(\text{operation}(rule_i))$$

ここで、Applicable と Do は、それぞれ操作ルールの条件部が適用可能である事、動作部の操作を行った事を示す述語である。また、関数 operation は、操作ルールを被験者が実行する事で起動する動作を返す。 σ_1 の意味は、被験者は E_t で、適用可能な操作ルール中、優先度が最大のルール $rule_i$ を利用する事である。

定義 2 (操作の継続: σ_2)

被験者は、時刻 t 以前に行った操作を、時刻 t においても継続して行う事がある。このような被験者の操作を示す述語として Continue を利用する。

定義 3 (制約知識: σ_3)

$$\forall rule_i, rule_j (rule_i, rule_j \in P \wedge (\text{condition}(rule_i) = \text{condition}(rule_j)) \Rightarrow (\text{operation}(rule_i) = \text{operation}(rule_j)))$$

σ_3 により、 P には、同一の条件部を持ちながら異なる動作部を持つルールが含まれない事になる。ここで、関数 condition は、引数の操作ルールの条件部であるリテラルの集合を返す。

次に、観測事象 G 、および時刻 t における観測事象 G_t を以下に定義する。

定義 4 観測事象 G

$$G \equiv (G_0 \wedge \dots \wedge G_t \wedge \dots \wedge G_{end})$$

定義5 時刻 t における観測事象 G_t

$$G_t \equiv (E_t \Rightarrow A_t)$$

ここで, A_t は, 時刻 t における被験者の操作を表す. 具体的には, ある操作の実行を意味する *Do* か, 操作の継続を意味する *Continue* で表現されたりテラルのいずれかとなる.

操作データに現れる観測事象は, 表 1 に示す述語を用いて記述される. 観測事象の記述例を以下に示す.

例 1 観測事象の記述例

$\text{Curve}(\text{Curve}_1) \wedge \text{InSight}(\text{Curve}_1, \text{self}) \wedge$

$\text{Uphill}(\text{Uphill}_1) \wedge \text{On}(\text{Uphill}_1, \text{self}) \wedge$

$\text{OverDesiredSpeed}(\text{self}) \wedge \text{Accelerating}(\text{self})$

$\Rightarrow \text{Do}(\text{ReleaseAccel}(\text{self}))$

2.5.2 モデル獲得プロセス

仮説推論に基づくモデル構築手法を用いて [4], 運転行動モデルを獲得する. 本手法により, 領域知識 Σ と仮説 H を用いて観測事象 G を説明するモデルが得られる. モデル構築アルゴリズムのプロセスを以下に示す.

- (1) 時刻 $t-1$ でのモデル $\mathcal{M} = \langle P, \preceq \rangle$ を入力
 - (2) 被験者が時刻 $t-1$ と同じ操作を時刻 t でも継続している場合, アルゴリズムは単に \mathcal{M} を返す.
 - (3) 被験者が時刻 t で新しい操作を実行した場合, E_t に適用可能, かつ A_t を説明可能な操作ルール p が, モデル \mathcal{M} を構成する操作ルール集合 P から選択される. 同時に, 選択されたルール p には, E_t で適用可能な P 中の全操作ルールより高い優先度が付与される (\preceq は \preceq' にアップデートされる). その後, アルゴリズムはモデル $\mathcal{M} = \langle P, \preceq' \rangle$ を返す.
 - (4) E_t で適用可能なルールが P に無い場合, $Rules$ から適用可能なルール p を選択する. 同時に, 選択されたルール p には, E_t で適用可能な $Rules$ 中の全操作ルールより高い優先度が付与される (\preceq は \preceq' にアップデートされる). その後, アルゴリズムはモデル $\mathcal{M} = \langle P \cup \{p\}, \preceq' \rangle$ を返す. ここで, $P \cup \{p\}$ が矛盾である場合, アルゴリズムは *fail* を返す. なお, 適用可能なルールが複数存在する場合, 各ルール選択毎に分岐し, モデル化処理が継続する. ただし, 計算量を抑えるためにモデルの生成数に上限を設け, 本論文では上限を 50 と設定した. 複数のモデルが得られた場合は, 被験者の操作と最も相関係数の高いモデルを選択する. 本論文での相関係数の定義は 4. で述べる.
- 提案手法では, 被験者の操作の説明が可能であれば, その被験者自身から獲得したルールと, 他の被験者が




図 3 ドライビングシミュレーションの走行環境
Fig. 3 Road Structure of a 3D Driving Simulator

ら獲得したルールを区別せず利用する. 提案手法では先験的知識の獲得において被験者間の共通性を意識しないが, 3. で後述するように, 複数のモデルに共通して含まれる知識も複数存在する. これは知識の補完的利用が有効に機能している事を示している.

モデル構築手法に関して, 説明に基づく学習 (Explanation-Based Learning: EBL) [6] の利用が別のアプローチとして考えられる. EBL では, 説明対象の事象を領域知識と訓練例に基づいて説明し, 定数の部分をパラメータ化することで一般的な知識の獲得を試みる. 一方, 仮説推論では, 観測事象に関して仮説を立て, 領域知識を用いて説明を試みる. 本論文での人間行動のモデル化では, 対象の人間がどのルールを持ち, どのルールの優先度が高いのか事前に分からない. そのため, ルールの保持や, ルール間の優先関係を仮説として事象の説明を行い, 行動系列を説明可能なモデルの獲得を試みる方が適切であり, 仮説推論の応用は妥当と言える.

3. 運転操作モデル獲得の実例

3.1 準備とモデリングプロセス

まず, 操作データを収集するためのドライビングシミュレーションの設定について述べる. 本実験では, 複数のカーブと勾配を含む全長 11km の仮想的な高速道路を用意した (図 3). 本実験では, 各被験者は単独で走行し, 道路線形と自身の走行状況に基づく操作を先験的知識として得る. 本実験では, ドライビングシミュレータの利用経験がある 36 人の全被験者から操作ルールが得られた. 得られた操作ルールを表 2 に示す. 本実験では, 被験者は高速道路で単独走行するため, アクセルのみを用いる被験者が大半であった. ブレーキを用いた被験者は数名存在したが, 論理的な理由の無いブレーキ使用であったためルール化されてい

RuleID	Description of a rule
rule ₀₁	If a subject is driving a curve, he/she releases the accelerator.
rule ₀₂	If a subject is driving a straight, he/she steps the accelerator.
rule ₀₃	If a subject is driving uphill, he/she steps on the accelerator.
rule ₀₄	If a subject is driving downhill, he/she releases the accelerator.
rule ₀₅	If a subject sees a curve ahead, he/she releases the accelerator.
rule ₀₆	If a subject sees a straight ahead, he/she steps the accelerator.
rule ₀₇	If a subject sees an uphill ahead, he/she steps on the accelerator.
rule ₀₈	If a subject sees a downhill ahead, he/she releases the accelerator.
rule ₀₉	If the speed exceeds the desired speed, a subject releases the accelerator.
rule ₁₀	If a subject is driving under the desired speed, he/she steps on the accelerator.
rule ₁₁	If a vehicle slow down, he/she steps on the accelerator.
rule ₁₂	If a vehicle speed up, he/she release the accelerator.

表 2 インタビューにより獲得した操作ルール
Table 2 Obtained knowledge from human subjects

ない。操作ルールは、周辺の道路環境、走行速度、希望巡航速度に基づいたアクセル使用に関する意思決定を表すものとなった。ルールの記述例を以下に示す。

例 2 (操作ルールの記述例)

rule₅:
if Curve(x) ^ InSight(x ,self) then ReleaseAccel(self)
rule₇:
if Uphill(x) ^ InSight(x ,self) then Accelerate(self)
例えば rule₅ は、前方にカーブ x があり (Curve(x)), もし被験者 ("self") の視野にカーブ x が入っていれば (InSight(x ,self)), 被験者はアクセルを緩める (ReleaseAccel(self)) 事を表している。

得られた操作ルールと観測事象を用いてモデルを構築する。例 1 および例 2 における操作ルールと観測事象を用いた例を以下に示す。本例では、Do(ReleaseAccel(self)) の導出の過程を示す。また、rule₁₂ ∈ P と仮定する。

(1) Do(ReleaseAccel(self)) の導出のためには、 σ_1 より、 $action(rule_i) = ReleaseAccel(self)$, $rule_i \in P$, および $rule_i = \max_{\preceq} \{rule | Applicable(rule, E_{t-1})\}$ が真である事を証明しなければならない。

(2) rule₅ の動作部が Initiate(ReleaseAccel(self)) であるため、 $action(rule_i) = ReleaseAccel(self)$ を成り立たせる rule _{i} の候補と成る。

ID	Driving behavior model
S ₁	$P = \{rule_{01}, rule_{03}, rule_{05}, rule_{09}, rule_{10}, rule_{11}\}$ $\preceq = \{rule_{10} \preceq rule_{01}, rule_{01} \preceq rule_{05}, rule_{10} \preceq rule_{05}, rule_{05} \preceq rule_{10}, rule_{01} \preceq rule_{10}, rule_{01} \preceq rule_{03}, rule_{05} \preceq rule_{03}, rule_{03} \preceq rule_{01}, rule_{03} \preceq rule_{09}, rule_{09} \preceq rule_{03}, rule_{09} \preceq rule_{05}, rule_{01} \preceq rule_{11}, rule_{05} \preceq rule_{11}, rule_{09} \preceq rule_{11}\}$
S ₂	$P = \{rule_{01}, rule_{02}, rule_{04}, rule_{05}, rule_{06}, rule_{09}, rule_{10}, rule_{11}\}$ $\preceq = \{rule_{01} \preceq rule_{04}, rule_{09} \preceq rule_{01}, rule_{01} \preceq rule_{11}, rule_{09} \preceq rule_{11}, rule_{11} \preceq rule_{09}, rule_{09} \preceq rule_{02}, rule_{02} \preceq rule_{06}, rule_{09} \preceq rule_{06}, rule_{02} \preceq rule_{09}, rule_{11} \preceq rule_{05}, rule_{05} \preceq rule_{11}\}$
S ₃	$P = \{rule_{01}, rule_{02}, rule_{03}, rule_{04}, rule_{05}, rule_{06}, rule_{11}\}$ $\preceq = \{rule_{04} \preceq rule_{02}, rule_{11} \preceq rule_{04}, rule_{04} \preceq rule_{11}, rule_{04} \preceq rule_{01}, rule_{11} \preceq rule_{01}, rule_{01} \preceq rule_{11}, rule_{06} \preceq rule_{05}, rule_{01} \preceq rule_{06}, rule_{11} \preceq rule_{06}, rule_{02} \preceq rule_{01}, rule_{02} \preceq rule_{06}, rule_{01} \preceq rule_{03}, rule_{05} \preceq rule_{03}, rule_{03} \preceq rule_{01}, rule_{03} \preceq rule_{11}, rule_{05} \preceq rule_{11}, rule_{11} \preceq rule_{03}, rule_{03} \preceq rule_{06}, rule_{02} \preceq rule_{03}, rule_{06} \preceq rule_{03}, rule_{03} \preceq rule_{05}\}$

表 3 仮説推論により獲得した走行モデル例
Table 3 Examples of obtained models

(3) rule₅ を rule _{i} に代入した場合:

(a) rule₅ ∈ P を証明するため、 H より仮説 rule₅ ∈ P を選定

(b) $rule_2 = \max_{\preceq} \{rule | Applicable(rule, E_{t-1})\}$ を証明するため、 H から、rule₇ ≼ rule₅ を選定

(c) $h_{t-1} = \{\{rule_{12}, rule_5\}, \{rule_7 \preceq rule_5\}\}$ が得られる。

本プロセスは、 G_{end} が説明されるまで繰り返され、出力は G を説明可能な運転行動モデルとなる。

3.2 獲得モデル例

表 3 に獲得したモデルの例を、図 4 に被験者とその被験者の走行を再現するモデル (エージェント) による走行速度と加速度の推移を示す。縦軸と横軸はそれぞれ速度と走行距離を表す。上方の 2 つのグラフが速度の推移を表し、下方の 2 つのグラフが加速度の推移を表す。色の濃い (太い) グラフが被験者のデータを、薄い (細い) グラフがモデルのデータを表す。

[ケース 1 : S₁]

被験者 S₁ の運転行動モデル \mathcal{M}_1 は 6 つの操作ルールから成る。図 3 に示す通り、走行環境の 1km-7km の区間は緩い上り勾配と複数のカーブから成る。被験者は、この区間を希望巡航速度 (120km/h) 以下で走行している (図 4(A-1))。 \mathcal{M}_1 は、rule₀₃, rule₀₇, および rule₁₀ の 3 つのルールにより、S₁ の運転を再現している。上り勾配の影響で速度が下がる一方、これ

ら3つのルールにより速度は維持もしくは上昇している。7km地点の後にはカーブしながらの下り勾配となる。S₁のモデルにはアクセルを緩めるルールが無いため、最初は走行速度が継続的に上昇している。しかし、希望巡航速度を超えると、rule₀₉の発火により加速が弱まる。一方、速度が極度に低下した場合、M₁は速度の回復が可能である。これはカーブ視認時、および走行中に加速を緩めるrule₀₁やrule₀₅よりも、低速時に加速するrule₁₁の方が優先度が高いためである。[ケース2：S₂]

被験者S₂の運転行動モデルM₂は8つの操作ルールから成る。S₂とS₁の速度推移は似ているが、例えば7km-9kmの区間には相違が見られる。S₁の速度が100km/hを超えるのに対し、S₂は100km/h周辺で走行している。M₂はこの違いを再現できている。M₂は、前方に下り勾配を視認した場合はアクセルを緩めるためのrule₄を含む。上述した通り、同じ区間でアクセルを緩める加速するS₁に比べ、S₂は加速を止めるため、速度差が生じている。

[ケース3：S₃]

S₃の運転スタイルは、図4(A-3)に示す通りアクセル操作頻度が高く、説明困難なものである。これは、100km/hの希望巡航速度の維持を強く意識しているためである。M₃はこの運転スタイルを、rule₁₀、およびrule₁₂によって再現している。希望巡航速度を下回ると速度を上げるが、加速を意識するとアクセルを離すという行動を繰り返すことで、小刻みな速度変化を繰り返している。図中の加速度の頻度からも、他とは異なる特徴的な運転スタイルの再現が確認できる。

4. 評価と考察

最初に、獲得モデルによる走行速度の再現を評価する。評価には、被験者と、その被験者から得られたモデルの走行速度の相関係数を用いる。ここでの相関係数は「同じ地点での運転速度」の相関を表し、仮想高速道路の0.01km毎にとった被験者とモデルの走行速度から、走行速度のデータ系列を生成し、2つのデータ系列を比較して計算する。相関係数は交通分野において認められている評価指標である[7]。表4(a)に被験者S₁、S₂、およびS₃と、各々のモデルによる速度の相関係数を示す。太字の数値は、被験者と、その被験者のモデル間の値を表すが、S₁とS₂に関しては妥当な結果が得られている。一方、S₃については最も相関が低い、それでも0.6を超える値が得られている。

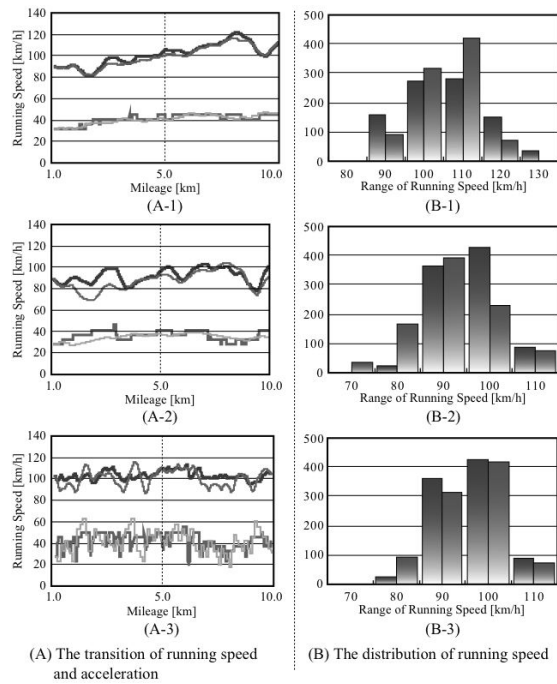


図4 被験者と運転行動モデルの速度と加速度の推移
Fig. 4 The transition of running speed and acceleration of human subjects and models

図5に全被験者に関する相関係数の度数分布を示す。相関係数の平均は0.72であり、ハイブリッドな運転行動モデルが、個別の運転操作を妥当な精度で再現したと評価できる。さらに、表4に示す数値から、各被験者の運転スタイルの再現を確認できる。例えば、S₁から得たモデルはS₁の走行に関しては相関が高いが、他の被験者に対しては必ずしも有効ではない。M₁とS₂、およびS₃の相関値は、0.62、および0.21と大幅に相関が低くなっている。特に図4(A)から予想できるように、M₃は、他の被験者に対する相関が大幅に低く、S₁およびS₂との相関値はそれぞれ0.05、0.1となっている。以上より、被験者の特徴的な操作を再現する運転行動モデルが獲得できたと評価できる。

次に走行速度の類似度について評価を行った。図4(B)に、被験者とモデルの走行速度の分布を示す。本図は、走行速度が各速度帯に含まれる度数の分布を表し、色の濃いグラフが被験者、薄いグラフがモデルの結果を表している。また、表4(b)に、S₁、S₂、およびS₃に関して、走行速度の平均値と標準偏差を示す。これらの結果から、全てのケースにおいて致命的な速度の乖離は無く、人間に近似した速度での走行が再現

		S_1		S_2		S_3	
		Human	Agent	Human	Agent	Human	Agent
S_1	Human	1	*	*	*	*	*
	Agent	0.95	1	*	*	*	*
S_2	Human	0.66	0.62	1	*	*	*
	Agent	0.90	0.87	0.72	1	*	*
S_3	Human	0.30	0.21	0.59	0.34	1	*
	Agent	0.05	-0.03	0.1	-0.03	0.61	1

(a) Correlation value for the speed of humans and agents

ID	Entity	Average	Standard Dev.
S_1	Human	100.9	10.6
	Agent	95.8	9.1
S_2	Human	91.6	7.18
	Agent	86.8	9.5
S_3	Human	102.9	5.32
	Agent	100.2	8.22

(b) Average and Standard deviation of the running speed

表 4 被験者と運転操作モデル間での速度に関する比較

Table 4 Comparison of the running speed




図 5 相関係数の度数分布

Fig. 5 Frequency of coefficient of correlation

できていると考察できる。特に S_1 については、速度の推移と速度の絶対値が共に近似しており、 S_3 についても、人間とモデルが近似した速度帯での高頻度の速度調整を繰り返しており、提案手法は、人間による走行の再現に関して妥当な性能を持つと評価できる。

モデル獲得実験では 36 人の被験者全員からモデルを獲得できた。提案手法では、1 人の被験者に対して複数のモデルが生成され得るが、実験では、被験者 1 人あたりのモデル生成数の最小値は 2、最大値は 50 で、平均モデル生成数は 36 であった。各被験者について相関係数が最大のモデルを比較した結果、モデルを構成するルール集合が同一の被験者は 1 組 (2 名) のみであり、これら 2 名の被験者も、ルールの優先関係 (モデル構造) は異なっていた。よって、提案手法は、個別の行動モデルを生成可能と言える。

5. 関連研究

Balmer らは、個々のエージェントが走行ルートの

見直しを反復するマルチエージェント交通シミュレーションを実現している [2]。この研究でのエージェントモデルは走行ルートの決定メカニズムのみを持つシンプルなもの、走行経路の最適化分析には有用だが、ミクロレベルの運転行動の再現には貢献しない。一方、Paruchuri らは、運転スタイルの多様性に着目した点は筆者らと共通だが [8]、実際の人間の運転行動の再現にはアプローチせず、パラメータに基づく 3 種類の運転スタイルの導入に留まっている。また、モデラーの判断に基づいたパラメータ設定は実際の運転スタイルを反映しているとは言えず、実データとの比較もない。

ユーザ参加型のモデリング手法は、マルチエージェントシミュレーションの既存研究において用いられている。Sempé らは、人間の被験者と、被験者毎に割り当てられたエージェントの間で行われる対話を通し、被験者の行動を説明する情報の抽出を試みている [9]。しかし、具体的なモデル構築方法には言及していない。また、Guyot らは、人間の提携形成の様子を観察し、インタラクションモデルの設計を試みている [10]、外部から見たエージェントモデルの分析と設計が研究の要諦であり、エージェント内部の行動決定メカニズムにフォーカスした筆者らとは目的が異なる。

文献 [11] では、ドライビングシミュレータを利用した運転挙動の分析を行っている。地震発生時の挙動や、地震警報を認知した人間の操作の変化を分析している。ただし、本文の主眼は人間の挙動分析にあり、本論文のように人間の行動を再現するモデルは構築していない。文献 [12] は、ドライビングシミュレータ上での、地震情報受信時の車両の挙動変化の検証実験を、マルチエージェントシミュレーションで代替する事を目的とし、人間の運転操作を再現するモデルを構築している。本論文では、モデルの構成要素と構造が固定されており、モデルに含まれるパラメータの設定にのみドライビングシミュレーションの結果が利用されている。一方、本論文の提案手法は、ドライビングシミュレーションの結果に基づいて各被験者の操作の説明に適用可能なルールを選び出し、それらの優先関係に基づいて構造化する。つまり、各被験者の操作の再現に適した構成要素と構造を持つモデルを構築するものである。

6. おわりに

本論文では、人間の振る舞いを再現するためのエージェントモデリングに関する新たなアプローチを示した。提案手法は、モデラーの知識や能力のみに依存せ

ず、参加型モデリングによって人間の行動に関する情報を得ることで、問題領域における人間の実際的な行動を実現する行動モデルの構築を可能にした。本論文では、運転行動モデル構築における先験的知識の不足という困難に対し、運転者横断的に知識を利用するアプローチを採った。この結果、得られるモデルは、複数の被験者からの知識が混合したハイブリッドなモデルとなるが、実験により、得られたモデルは個々の運転スタイルの再現に十分な性質を持つことを確認した。

本論文の提案手法によって生成されたモデルは、構成要素に大きな違いがなければ、異なる道路環境に適用する事が可能である。しかし、例えば本論文で生成したモデルを、市街地での運転の再現に適用するのは困難である。これは信号や交差点など、高速道路環境にはない要素が存在するためである。市街地のような複雑な環境でのモデル構築は今後の課題であり、モデルの適用性についても検討を要する。また、提案手法によるモデルは特定の環境での人間の行動を定性的に表現するが、どのように行動するかを定量的に表現しない。具体的には、アクセルの踏み込み量などの情報を持たない。3.2のケース3の精度低下はこのようなモデルの性質に起因すると考えられるため、精度向上のために、行動の特徴を表す定量的なパラメータの組込みが必要である。最後に、本論文では、運転者間の相互作用がモデルに反映されていない。本論文では、走行環境と人間の運転操作の関係に注目したモデルを生成したが、次のステップとして、運転者間の相互作用の反映が必要である。

謝辞 本研究はパナソニック・京都大学共同研究「個の行動・嗜好に基づく群行動のナビ制御による地域EMSの実現」、および京都大学グローバルCOEプログラム「知識循環社会のための情報学教育研究拠点」の補助を受けて行われた。

文 献

- [1] N. Gilbert and K.G. Troitzsch, Simulation for the social scientist, Open University Press, 1999.
- [2] M. Balmer, N. Cetin, K. Nagel, and B. Raney, "Towards truly agent-based traffic and mobility simulations," Proc. AAMAS-2004, pp.60-67, 2004.
- [3] T. Yamashita, K. Izumi, K. Kurumatani, and H. Nakashima, "Smooth traffic flow with a cooperative car navigation system," Proc. AAMAS-2005, pp.478-485, 2005.
- [4] Y. Murakami, Y. Sugimoto, and T. Ishida, "Modeling human behavior for virtual training systems," Proc. AAAI-05, pp.127-132, 2005.

- [5] 飯田克弘, 池田武司, 河井健, 森康男, 山岸将人, "プロトコル法を用いた運転者挙動分析結果に基づくサグ部の道路構造改善方針の検討," 土木計画学研究論文集, vol.18, no.5, pp.919-926, 2001.
- [6] R.J. Mooney, "Learning plan schemata from observation: Explanation-based learning for plan recognition," Cognitive Science, vol.14, pp.483-509, 1990.
- [7] J. Hourdakis, P.G. Michalopoulos, and J. Kottommannil, "Practical procedure for calibrating microscopic traffic simulation models," Proc. of TRB-03, pp.130-139, 2003.
- [8] P. Paruchuri, A.R. Pullalarevu, and K. Karlapalem, "Multi agent simulation of unorganized traffic," Proc. AAMAS-2002, pp.176-183, 2002.
- [9] F. Sempé, M.D. Nguyen, A. Boucher, and A. Drogoul, "An artificial maieutic approach for eliciting experts' knowledge in multi-agent simulations," Proc. AAMAS-2005, pp.1361-1362, 2005.
- [10] P. Guyot, A. Drogoul, and S. Honiden, "Power and negotiation: Lessons from agent-based participatory simulations," Proc. AAMAS-2006, pp.27-33, 2006.
- [11] 丸山喜久, 山崎文雄, "ドライビングシミュレータを用いた地震動早期警報の効果検討," 土木学会論文集, vol.I-71, no.787, pp.177-186, 2005.
- [12] 松本和貴, 丸山喜久, 山崎文雄, "マルチエージェント・シミュレーションを用いた高速道路走行車両に与える緊急地震速報の影響に関する検討," 地域安全学会論文集, no.10, pp.321-330, 2008.

(平成 xx 年 xx 月 xx 日受付)

服部 宏充 (正員)

平成 16 年名古屋工業大学大学院博士課程修了。平成 16 年学振特別研究員。リバプール大学、マサチューセッツ工科大学客員研究員を経て、現在、京都大学大学院情報学研究所助教。工学博士。マルチエージェントシミュレーションに興味を持つ。

中島 悠

平成 18 年 京都大学大学院情報学研究所社会情報学専攻修士課程修了。現在、同大学院博士課程在学中。学振特別研究員。大規模マルチエージェントシステム、マルチエージェントシミュレーションに関心を持つ。

石田 亨 (正員)

昭和 51 年京都大学工学部情報学工学科卒業、昭和 53 年 同大学院修士課程修了。同年日本電信電話公社電気通信研究所入所。現在、京都大学大学院情報学研究所教授。工学博士。人工知能、社会情報システムに興味をもつ。

Abstract Multiagent-based simulation (MABS) is a very active interdisciplinary area bridging multi-agent research and social science. The key technology to conduct realistic MABS is agent modeling. In order to make agent models realistic, it seems natural to learn from human behavior in the real world. The challenge presented in this paper is to obtain an individual behavior model by using participatory modeling technology in the traffic domain. We show a methodology that can elicit prior knowledge for explaining human driving behavior in specific environments, and then construct a driving behavior model based on a set of prior knowledge. In the real world, human drivers often perform unintentional actions, and occasionally they have no logical reason for their actions. In these cases, we cannot elicit prior knowledge to explain them. We are forced to construct a behavior model with an insufficient amount of knowledge to reproduce driving behavior. To construct an individual driving behavior model with insufficient knowledge, we take the approach of using knowledge from others to complement the lack of knowledge from oneself. To clarify that the behavior model, which is filled out by knowledge from others, offers driving behavior individuality, we experimentally confirm that the driving behaviors reproduced by the hybrid model correlate reasonably well with human behavior.

Key words multiagent simulation, agent modeling, traffic simulation