

車両歩行者間のインタラクション行動のモデル化のための 2段階入出力隠れマルコフモデル

新村 文郷^{1,2,a)} 赤井 直紀² 平山 高嗣^{2,3} 劉 海龍^{2,4} 川西 康友^{2,5} 出口 大輔² 村瀬 洋²

受付日 2021年12月2日, 採録日 2022年5月9日

概要: 自動車と歩行者が交差するシーンに着目し, 車両歩行者間のインタラクティブな行動をモデル化するための2段階入出力隠れマルコフモデル (TS-IOHMM) を提案する. 従来の入出力隠れマルコフモデルは, 相手の行動に依存して自己の意図と行動が決定される過程をモデル化した. 提案する TS-IOHMM は, 相手の行動の影響に加え, 自己の行動もまた相手の意図に影響を与える点を考慮したモデルで, これまで注目されなかった意図と行動の変化にある法則性 (ルール) の獲得を目指したモデルである. 検証用に設定したルールに従って意図や行動が変化するシミュレーションデータを作成し, それを用いて提案モデルがどのようなルールを獲得できるか検証する実験を行った. その結果から, 提案モデルがシミュレーションと同等の意図や行動を出力する行動ルールを獲得できたことを確認した.

キーワード: 運転行動モデリング, 車両歩行者間インタラクション, 隠れマルコフモデル

Two-Stage Input-Output Hidden Markov Model for Car-Pedestrian Interaction Behavior Modeling

FUMITO SHINMURA^{1,2,a)} NAOKI AKAI² TAKATSUGU HIRAYAMA^{2,3} HAILONG LIU^{2,4}
YASUTOMO KAWANISHI^{2,5} DAISUKE DEGUCHI² HIROSHI MURASE²

Received: December 2, 2021, Accepted: May 9, 2022

Abstract: This paper presents the Two-Stage Input-Output Hidden Markov Model (TS-IOHMM) which is a modeling method for interactive behavior between a car and a pedestrian focusing on the scene where the car and the pedestrian intersect. The conventional Input-Output Hidden Markov Model (IOHMM) models the process that the driver's intention and behavior are determined depending on the behavior of the pedestrian. The proposed TS-IOHMM is a model that considers not only the influence of the pedestrian's behavior, but also that the driver's behavior affects the pedestrian intention. In this paper, we aim to acquire a rule in the change of the driver's intentions and behaviors by the proposed model. We generated simulation data in which the driver's intentions and behaviors change according to a certain rule, and conducted experiments to evaluate that the proposed model was able to correctly provide intentions and behaviors equivalent to those according to the rule.

Keywords: driving behavior modeling, car-pedestrian interaction, hidden Markov model

¹ 成蹊大学
Seikei University, Musashino, Tokyo 180-8633, Japan

² 名古屋大学
Nagoya University, Nagoya, Aichi 464-8601, Japan

³ 人間環境大学
University of Human Environments, Okazaki, Aichi 444-3505, Japan

⁴ 奈良先端科学技術大学院大学
Nara Institute of Science and Technology, Ikoma, Nara 630-0192, Japan

⁵ 理化学研究所
RIKEN, Sorakugun, Kyoto 619-0288, Japan

1. はじめに

本稿では, 自動車と歩行者が交差するシーンに焦点を当て, これを円滑に実現するインタラクティブな行動ルールの獲得を行うことを目的とする. 他者と円滑に行動するためには, 相手の意図 (行動決定の方針) を知る事が重要とされる [1]. インタラクション中は互いの行動によって

a) shinmuraf@st.seikei.ac.jp

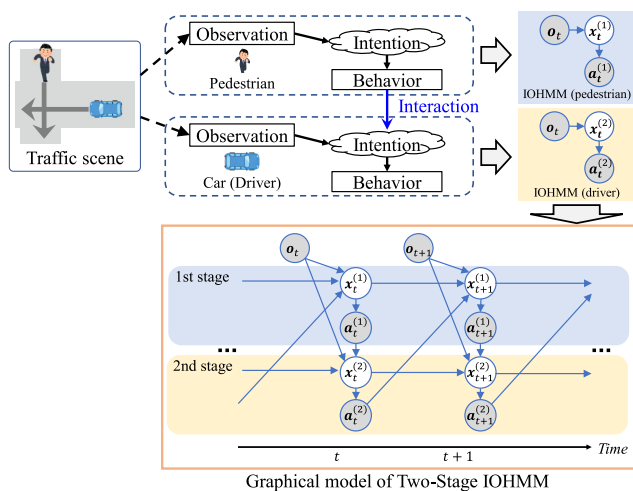


図 1 対象とする交通シーンと TS-IOHMM の概要

Fig. 1 Target traffic scene and outline of TS-IOHMM.

互いの意図や行動が時々刻々と変化するため、意図や行動の変化の法則性を獲得することが重要と考える。我々は、当該シーンにおけるインタラクティブな行動には意図と行動が変化する行動ルールがあり、そのルールに基づいて、両者の行動が互いの意図に影響を与えながら、それぞれの意図と行動が時々刻々と変化すると仮定する。特に車両と歩行者間のインタラクションでは、運転者の行動（以下、運転行動）は歩行者の行動に強く影響を受けると考えている。このような行動ルールを獲得することを目指し、2段階入出力隠れマルコフモデル (TS-IOHMM) を提案する。

車両歩行者間のインタラクション行動をモデル化するために、両者の行動が互いの意図に影響を与えることをどのように表現するかが重要と考えられる。従来の研究では、入出力隠れマルコフモデル (IOHMM) を用いた行動モデル化が行われ、相手の行動を入力してそれに依存して潜在変数を遷移させることで、相手の行動が自己の意図に影響を与えることを表現している [9]。しかし、IOHMM に基づく運転モデルでは相手の意図が考慮されておらず、自己の行動に依存して相手の意図や行動が変化する点も考慮されていない。また、観測された行動をもとに意図を推定する研究 [8], [18] が主で、既存研究では両者の意図や行動が変化する行動ルールを獲得した研究はなかった。これらの問題を解決するため、提案する TS-IOHMM では相手の意図を明示的に考慮し、両者の行動が互いの意図に影響を与える依存関係を表現する。本稿は TS-IOHMM を利用して行動ルールの獲得を目指す。

図 1 の左上に対象とする場面の 1 例を図に示す。本稿が対象とする自動車と歩行者が交差するシーンでは、運転者は歩行者の行動を観察して歩行者の意図を推定しつつ行動を予測し、自身の行動を決定すると考える。提案する TS-IOHMM は、IOHMM を 2 段に連結した構造を持ち、歩行者の行動決定過程を表現する IOHMM (歩行者の

IOHMM) と、運転者の行動決定過程を表現する IOHMM (運転者の IOHMM) から構成される。歩行者の IOHMM の出力を運転者の IOHMM の入力へ追加し、歩行者の行動から運転者が強く影響を受けることを表現する。また、運転行動を見て歩行者も反応すると予測されることから、運転者の IOHMM の出力を次フレームの歩行者の IOHMM への入力に加える。1 つの潜在変数によって表現できる人間の意図には限界があるが、本稿では獲得した行動ルールを解釈しやすいようにシンプルな構成のモデルを用いることとした。TS-IOHMM の概要を表したものが図 1 である。図 1 の下側には TS-IOHMM をグラフィカルモデルにより示しており、詳細は 3 章で説明する。

TS-IOHMM の有効性を示すため、自動車と歩行者が安全かつ円滑に道路上で交差する交通シーンで実験を行う。ただし、実環境では運転者の意図は観測できないため、行動ルールの正解を与えられない。そこで、明確な行動ルールを定めたシミュレーションを用いた評価を行う。本稿では、TS-IOHMM を用いて車両 (運転者) や歩行者の速度を予測する。車両の速度制御はアクセルとブレーキによる加減速によって行われることから、行動ルールとして加減速の切替パターンが抽出されると想定する。そして、TS-IOHMM が時々刻々と加減速を変化させて速度を出力していることを示し、シミュレーションの運転行動を再現できていることを示す。

本稿では、車両歩行者間のインタラクション行動のモデル化の第 1 段階として、実際の交通シーンよりも状況を限定してモデル化を行う。両者の行動は、運転者の心理状態や運転経験、運転スタイルといった運転者属性や、天候や道路環境といった外的要因にも影響を受けるが、まずはこれらを考慮しない単純な状況を想定してインタラクション行動をモデル化し、車両歩行者間の相互の影響に焦点を当ててモデル化することで、行動ルールが正しく獲得できることを確認する。本稿では、車両と歩行者が 1 対 1 の状況下で両者が垂直に交差し、互いの位置や速度から影響を受けて行動する場面を想定する。本状況は単純ではあるが非常に一般的な場面であり、日本自動車アセスメント (JNCAP) [22] の衝突被害軽減ブレーキの評価においても、直進する車両に対し左から歩行者が横断する状況での評価が行われている。また、単純な状況下においても車両歩行者間のインタラクション行動のモデル化はまだ不十分で、モデル評価のために本状況を再現するシミュレーションが提案され [19] 研究されており、本稿が想定する状況でのモデル化にも価値がある。

2. 関連研究

自動車や歩行者の意図推定や行動予測のため、行動のモデル化について様々な研究が行われてきた。本稿では、モデル化にあたり、獲得した行動ルールが人間に解釈可能な

点を重要と考える。そのため、人間の意図に相当するものを明示的に考慮した研究について概観する。

意図は人間の内部状態であり、直接観測できない。観測できる歩行者の行動をもとに第三者が歩行者の横断意図のラベルを付け、それを深層ニューラルネットワークで学習することで横断意図を推定する研究が報告されている [16]。しかし、この方法で推定できる人間の内部状態は、1つの映像を観察して1つの状態を選べるような単純なものに限られる。実際には映像中の人間の内部状態は時々刻々と変化するので、それほど単純ではない。それゆえ、人間の内部状態を潜在変数や離散状態によって表現できる HMM やハイブリッドダイナミカルシステム (HDS) によるモデル化が用いられてきた [9], [13]。Wu らは、歩行者の道路横断シーンにおいて、歩行者の横断意図や危険の有無を内部状態として表現し、それに基づいて行動が決定される流れをモデル化した [18]。同様に、内部状態の表現として潜在変数を用いたモデルが提案されている [14]。これらのように、本研究でも運転者や歩行者の意図に基づく行動決定過程を HMM を用いてモデル化する手法を用いる。

人間は観測した情報をもとに様々な判断を下すので、観測情報に基づいて内部状態が変化し、これを表現するため、入力（観測情報）に依存して潜在変数が遷移し、その潜在変数から出力（行動）を決定する IOHMM が用いられている。Jain らは、車を運転するシーンを想定して、観測した車外の環境に依存して運転者の内部状態が変化し、それに基づいて車内での行動が決定される流れをモデル化した [12]。また、Akai らは、観測した自己位置や周囲環境に依存して運転者の内部状態が変化し、それに基づいて視線等の行動が決定される流れをモデル化した [2]。これらの研究では、観測情報に依存して運転者の内部状態が変化するモデル化が実現されている。ただし、歩行者の存在しない環境下での運転行動のモデル化であり、他者とのインタラクションを考慮したモデルではない。

IOHMM を用いた人間の行動モデルにおいて、他者の行動を入力として用いることで、他者の行動から影響を受けて人間の内部状態が変化することを表現することができる。Dong らは、斜道から車両が合流するシーンにおいて、2台の車両の合流地点への到達時間に応じて潜在変数が変化し、それに基づいて合流車の速度が決定される流れをモデル化した [8]。このモデルでは潜在変数が「道を譲るか否か」の意図を表しており、相手の行動に依存してその意図が変化し、また、Blaiotta は、5種類の潜在変数を持つベイジアンネットワークを用いて、横断する歩行者の行動をモデル化した [4]。Blaiotta のモデルの潜在変数は歩行者の横断意図や対向車への注意、歩行か停止かの選択といった内部状態を表現しており、観測された車両の行動に依存して各潜在変数が決定し、それらに基づいて歩行者の動きや体向きが出力される。これらの研究では、他者の行動か

ら自己の内部状態に与える影響は考慮しているものの、他者の内部状態は考慮されていない。したがって、自己の行動が他者の内部状態へ影響を与え、それに基づいて他者の行動もまた変化するということを表現できていない。

インタラクションにおける双方向の影響を考慮してモデル化した研究では、Coupled HMM が提案されている [5]。人間同士のインタラクションに対しては、ゲーム中のインタラクションのモデル化に適用した研究が報告されている [15]。2つの HMM を結合した Coupled HMM では、一方の HMM の潜在変数の出力を他方の HMM の潜在変数が次の時刻の入力として受け取る。この依存関係を相互に持つことで、2つの HMM が互いに影響し合う関係を表現した。ただし、押川らの研究 [15] は旗揚げゲームを対象としたものであって、交通シーンに対しては適用されておらず、運転者の行動モデルではない。また、我々は運転者や歩行者の内部状態が受ける影響は観測される行動によるものと考え、潜在変数間で依存関係を持つモデルの構造は、我々の考える運転行動の決定過程とは異なる。

運転者と歩行者の視点でそれぞれ行動をモデル化し、これを組み合わせて歩行者の行動予測を行うモデルが提案されている [21]。このモデルは車両行動が考慮されて歩行者行動が予測されるが、予測された歩行者行動もまた車両行動に影響を与えることは考慮されていない。双方向の影響が考慮されていないという点では、Dong らのモデル [8] や Blaiotta のモデル [4] と同様である。我々は、両者の行動が互いの行動に影響し合うことを表現するため、車両行動もまた歩行者行動の影響を受けることを考慮する。

以上の関連研究を考慮し、我々は図 1 の車両歩行者間のインタラクションを表現するために、運転者と歩行者の両方の行動が互いの内部状態へ影響を与えつつ時々刻々と行動が決定される過程を表現したモデルを提案する。また、従来研究では内部状態が変化する行動ルールについて分析されてこなかったため、本稿では提案モデルが獲得した行動ルールを分析し、具体的にどのような運転者の意図や行動の変化として解釈できるか明確にして、それについて評価を行う。

3. 2段階入出力隠れマルコフモデル

車両が片側 1 車線の道路や生活道路を走行中に、横断しようとする歩行者に遭遇することは日常的にみられるインタラクションの場面である。道路を走行する車両とその前方を横断しようとする歩行者が交差する場面を想定する。信号機や横断歩道がなく、運転者と歩行者は互いの存在に気付いていることを前提とする。このとき、両者は安全かつ円滑に通行するために、互いの行動を考慮しつつ行動するものとする。この場面で車両の速度を予測するためのモデルを考える。

3.1 TS-IOHMM による運転行動のモデル化

図 1 下側に提案する TS-IOHMM のグラフィカルモデルを示す。ここで、グラフィカルモデルの網掛けの頂点は観測変数を、白色の頂点は潜在変数を表す。運転者と歩行者が互いを目視したと想定する。運転者と歩行者は相手の姿を見て位置関係を把握できるので、両者ともに車両と歩行者の位置を観測情報として用いる。このとき、歩行者の位置が道路内か道路外かは、歩行者や運転者の内部状態に与える影響が大きい。そこで、車両と歩行者の位置は、歩行者が道路内か道路外かを区別するための値 (2 値) を含むものとし、その値は歩行者の位置をもとに決定する。また、歩行者は車両の動きを、運転者は歩行者の動きをそれぞれ観測するので、車両の速度や歩行者の速度を観測情報として用いる。これらの観測情報が得られるもとの、各時刻における車両と歩行者の速度の確率を求める。時刻 $t \in \{1, \dots, \tau\}$ とすれば、求める確率は $P(\mathbf{a}_t^{(1)}, \mathbf{a}_t^{(2)}, \mathbf{X}_t^{(1)}, \mathbf{X}_t^{(2)} | \mathbf{O}_t, \mathbf{A}_{t-1}^{(1)}, \mathbf{A}_{t-1}^{(2)})$ で表される。ここで、 $\mathbf{A}_t^{(n)} = \{\mathbf{a}_1^{(n)}, \mathbf{a}_2^{(n)}, \dots, \mathbf{a}_t^{(n)}\}$, $\mathbf{X}_t^{(n)} = \{\mathbf{x}_1^{(n)}, \mathbf{x}_2^{(n)}, \dots, \mathbf{x}_t^{(n)}\}$, $\mathbf{O}_t = \{\mathbf{o}_1, \mathbf{o}_2, \dots, \mathbf{o}_t\}$ である。 $\mathbf{a}_t^{(1)}$ は歩行者の速度、 $\mathbf{a}_t^{(2)}$ は車両の速度をそれぞれ表す。 $\mathbf{x}_t^{(1)}$, $\mathbf{x}_t^{(2)}$ はそれぞれ離散潜在変数である。 \mathbf{o}_t は車両と歩行者の位置を表す。 $\mathbf{a}_t^{(1)}$, $\mathbf{a}_t^{(2)}$ がそれぞれ $\mathbf{x}_t^{(1)}$, $\mathbf{x}_t^{(2)}$ のみに依存し、それぞれの潜在変数にマルコフ性を仮定することで、以下で表される。

$$\begin{aligned} & P(\mathbf{a}_t^{(1)}, \mathbf{a}_t^{(2)}, \mathbf{X}_t^{(1)}, \mathbf{X}_t^{(2)} | \mathbf{O}_t, \mathbf{A}_{t-1}^{(1)}, \mathbf{A}_{t-1}^{(2)}) \\ &= P(\mathbf{a}_t^{(2)} | \mathbf{x}_t^{(2)}) P(\mathbf{x}_t^{(2)} | \mathbf{x}_{t-1}^{(2)}, \mathbf{o}_t, \mathbf{a}_t^{(1)}) \\ & P(\mathbf{a}_t^{(1)} | \mathbf{x}_t^{(1)}) P(\mathbf{x}_t^{(1)} | \mathbf{x}_{t-1}^{(1)}, \mathbf{o}_t, \mathbf{a}_t^{(2)}) \end{aligned} \quad (1)$$

説明のため、入力変数 $\mathbf{i}_t^{(n)}$ ($n \in \{1, 2\}$) を

$$\mathbf{i}_t^{(1)} := [\mathbf{o}_t, \mathbf{a}_{t-1}^{(2)}] \quad (2)$$

$$\mathbf{i}_t^{(2)} := [\mathbf{o}_t, \mathbf{a}_t^{(1)}] \quad (3)$$

と置く。 n 番目の潜在変数 $\mathbf{x}_t^{(n)}$ は、直前の状態 $\mathbf{x}_{t-1}^{(n)}$ と入力変数 $\mathbf{i}_t^{(n)}$ に基づき決定される。潜在変数 $\mathbf{x}^{(n)}$ がとる状態数を s_n とすれば、 $\mathbf{x}_t^{(n)}$ は離散的な値をとるため s_n 次元の二値変数で定義することができ、 $\mathbf{x}_t^{(n)} = (x_{t,1}^{(n)}, \dots, x_{t,s_n}^{(n)})$ で表される。このとき $\mathbf{x}_t^{(n)}$ は、 $x_{t,j}^{(n)} \in \{0, 1\}$ かつ $\sum_j x_{t,j}^{(n)} = 1$ ($j \in \{1, \dots, s_n\}$) を満たす one-hot ベクトルである。そのため潜在変数が直前の状態に依存するとき、入力変数 $\mathbf{i}_t^{(n)}$ が与えられたときの $\mathbf{x}_t^{(n)}$ の確率は遷移確率 $\omega_{jk}^{(n)} \equiv p(x_{t,k}^{(n)} = 1 | x_{t-1,j}^{(n)} = 1)$ を用いて表すことができる。ここで、遷移確率は入力変数に依存する。入力変数 $\mathbf{i}_t^{(n)}$ は κ_n 個のクラスに分類できるものとする、 $c = f(\mathbf{i}_t^{(n)}) \in \{1, \dots, \kappa_n\}$ のときの遷移確率を $\omega_{jkc}^{(n)} \equiv p(x_{t,k}^{(n)} = 1 | x_{t-1,j}^{(n)} = 1, c = f(\mathbf{i}_t^{(n)}))$ とすれば、入力変数 $\mathbf{i}_t^{(n)}$ が与えられたときの潜在変数 $\mathbf{x}^{(n)}$ の確率分布は以下で表される。

$$p(\mathbf{x}_t^{(n)} | \mathbf{x}_{t-1}^{(n)}, \mathbf{i}_t^{(n)}) = \prod_{j=1}^{s_n} \prod_{k=1}^{s_n} \hat{\omega}^{x_{t,k}^{(n)} x_{t-1,j}^{(n)}} \quad (4)$$

$$\hat{\omega} = \omega_{jkc}^{(n)}$$

ただし、 $t = 1$ のときは入力変数のみに依存した初期確率 $\phi_{jc}^{(n)} \equiv p(x_{1,j}^{(n)} = 1 | c = f(\mathbf{i}_1^{(n)}))$ を用いて以下で表される。

$$p(\mathbf{x}_1^{(n)} | \mathbf{i}_1^{(n)}) = \prod_{j=1}^{s_n} \hat{\phi}^{x_{1,j}^{(n)}} \quad (5)$$

$$\hat{\phi} = \phi_{jc}^{(n)}$$

$f(\cdot)$ はクラスタリングを表す。本手法では事前に学習用データに含まれる入力変数群に対して k -means 法を適用し、得られた各クラスターの平均値を代表点 $\mathbf{m}^{(n)}$ として求めておき、 $f(\mathbf{i}_t^{(n)})$ は $\mathbf{i}_t^{(n)}$ から最も近い代表点を持つクラスターを求める。

時刻 t における n 番目の出力変数 $\mathbf{a}_t^{(n)}$ は、同時刻の潜在変数 $\mathbf{x}_t^{(n)}$ に基づき決定される。提案モデルでは、潜在変数 $\mathbf{x}_t^{(n)}$ が与えられたときの出力変数 $\mathbf{a}_t^{(n)}$ の確率分布は以下で表される。

$$p(\mathbf{a}_t^{(n)} | \mathbf{x}_t^{(n)}) = \prod_{j=1}^{s_n} \mathcal{N}(\mathbf{a}_t^{(n)} | \boldsymbol{\mu}_j^{(n)}, \boldsymbol{\Sigma}_j^{(n)})^{x_{t,j}^{(n)}} \quad (6)$$

ここで、 $\mathcal{N}(\cdot)$ は正規分布、 $\boldsymbol{\mu}_j^{(n)}$, $\boldsymbol{\Sigma}_j^{(n)}$ はそれぞれ $x_{t,j}^{(n)}$ のときの $\mathbf{a}_t^{(n)}$ の平均と共分散を表す。

3.2 パラメータの学習

提案モデルは次のパラメータを持つ： $\Theta = \{\boldsymbol{\mu}_i^{(1)}, \boldsymbol{\mu}_j^{(2)}, \boldsymbol{\Sigma}_i^{(1)}, \boldsymbol{\Sigma}_j^{(2)}, \boldsymbol{\omega}_{ikr}^{(1)}, \boldsymbol{\omega}_{jls}^{(2)}, \boldsymbol{\phi}_{ik}^{(1)}, \boldsymbol{\phi}_{jl}^{(2)}\}$ ($i = 1, \dots, s_1, j = 1, \dots, s_2, k = 1, \dots, s_1, l = 1, \dots, s_2, r = 1, \dots, \kappa_1, s = 1, \dots, \kappa_2$)。これらのパラメータを決定するため、学習用データをもとに最適なパラメータを最尤推定により決定する。具体的には、次の対数尤度関数を最大化するパラメータを、EM (Expectation Maximization) アルゴリズムを用いて推定する [6]。

$$\ln p(\mathcal{D} | \Theta) = \sum_X \ln(p(\mathcal{D}, X | \Theta)) \quad (7)$$

ここで、 \mathcal{D} は学習用のすべての観測データの集合を表し、各時刻での観測された入力変数や出力変数の値が含まれる。また、 $X \in \{\mathbf{x}_1^{(1)}, \dots, \mathbf{x}_\tau^{(1)}, \mathbf{x}_1^{(2)}, \dots, \mathbf{x}_\tau^{(2)}\}$ はすべての潜在変数の集合を表す。まず、パラメータの初期値 Θ^{old} を適当に選んで初期化する。EM アルゴリズムの E ステップでは、 Θ^{old} を用いて潜在変数の事後確率 $p(X | \mathcal{D}, \Theta^{\text{old}})$ を算出する。EM アルゴリズムの M ステップでは、E ステップで求めた事後確率を用いて、 $\ln p(\mathcal{D}, X)$ の期待値を最大化する。この期待値

$$Q(\Theta, \Theta^{\text{old}}) = \sum_X p(X | \mathcal{D}, \Theta^{\text{old}}) \ln p(\mathcal{D}, X | \Theta) \quad (8)$$

を Θ について最大化することで Θ^{new} を得る.

$$\Theta^{\text{new}} = \arg \max_{\Theta} Q(\Theta, \Theta^{\text{old}}) \quad (9)$$

算出した Θ^{new} により Θ^{old} を更新する.

$$\Theta^{\text{old}} \leftarrow \Theta^{\text{new}} \quad (10)$$

再び E ステップの処理へ戻り, 設定した収束条件が満たされるまで E ステップと M ステップを交互に繰り返すことで, 最適なパラメータ Θ を求める. 本手法では, 収束条件として尤度関数の変化が 0.0001 よりも小さくなるか, 処理を 100 回繰り返すまでとした.

3.3 運転行動の予測

ここでは TS-IOHMM を用いて将来の運転行動を予測する方法を述べる. 予測では, 現時刻 t_c のとき, 時刻 $t_c + 1$ から $t_c + t_f$ までの各出力変数の予測値を求める. このとき, 時刻 $t_c - t_p$ から t_c までの観測情報および各出力変数の値 (歩行者と車両の速度) は得られているものとする.

まず, 過去の情報を用いて現時刻の潜在変数 $\mathbf{x}_{t_c}^{(2)}$ の確率を求める. 初期時刻を $t_c - t_p$ として, 得られている観測情報および各出力変数の値を用いて各潜在変数の確率を更新する. 各潜在変数 $\mathbf{x}_t^{(n)}$ の確率は式 (4) により算出されるが, 各出力変数の値が得られている場合, それを考慮して潜在変数 $\mathbf{x}_t^{(n)} = j \in \{1, \dots, s_n\}$ の確率分布は次式で算出される.

$$\begin{aligned} \widehat{p}(\mathbf{x}_{t,j}^{(n)} | \mathbf{x}_{t-1}^{(n)}, \mathbf{i}_t^{(n)}) &= \frac{\Psi_j}{\sum_{j=1}^{s_n} \Psi_j} \\ \Psi_j &= p(\mathbf{x}_{t,j}^{(n)} | \mathbf{x}_{t-1}^{(n)}, \mathbf{i}_t^{(n)}) p(\mathbf{x}_{t,j}^{(n)} | \mathbf{a}_t^{(n)}) \end{aligned} \quad (11)$$

このとき, $p(\mathbf{x}_{t,j}^{(n)} | \mathbf{a}_t^{(n)})$ は以下の式で得られる.

$$\begin{aligned} p(\mathbf{x}_{t,j}^{(n)} | \mathbf{a}_t^{(n)}) &= \frac{1}{(\sqrt{2\pi})^d \sqrt{|\Sigma_j^{(n)}|}} \exp\left(-\frac{1}{2} \Lambda\right) \\ \Lambda &= \left(\mathbf{a}_t^{(n)} - \boldsymbol{\mu}_j^{(n)}\right)^T \left(\Sigma_j^{(n)}\right)^{-1} \left(\mathbf{a}_t^{(n)} - \boldsymbol{\mu}_j^{(n)}\right) \end{aligned} \quad (12)$$

ここで, d は出力変数の次元数である. 現時刻 t_c まで 1 フレームずつ各潜在変数の確率の更新を繰り返すことで, 現時刻の潜在変数 $\mathbf{x}_{t_c}^{(2)}$ の確率を得る. また, 各時刻の潜在変数の確率をもとにサンプリングすることで, 各時刻の潜在変数が得られる.

次に, 時刻 t_c から $t_c + t_f$ までの各出力変数の予測値を求める. 時刻 t_c から順に 1 フレームずつ, 伝承サンプリング (ancestral sampling) を用いて各出力変数の値をサンプリングする [6]. まず, 式 (4) により 1 番目の潜在変数 $\mathbf{x}_t^{(1)}$ の確率を算出し, その確率に従って $\mathbf{x}_t^{(1)}$ の値をサンプリングする. 決定した $\mathbf{x}_t^{(1)}$ の値を用いて式 (6) により 1 番目の出力変数 $\mathbf{a}_t^{(1)}$ の確率を算出し, その確率に従って $\mathbf{a}_t^{(1)}$

の値をサンプリングする. 同様にして, 2 番目の潜在変数 $\mathbf{x}_t^{(2)}$ と出力変数 $\mathbf{a}_t^{(2)}$ を順にサンプリングすることで, 各出力変数の予測値を求める. ここで, 時刻 t_c 以降は未来の事象なので, 観測情報 \mathbf{o}_t ($t > t_c$) が得られていない. そのため, 予測した出力変数の値を用いて観測情報を更新することで, 仮想的に次の時刻の観測情報が得られたものとして将来の運転行動を予測する. 本手法では観測情報は車両と歩行者の位置であるから, 予測した歩行者の速度 $\mathbf{a}_t^{(1)}$ と車両の速度 $\mathbf{a}_t^{(2)}$ を用いて, 次の時刻の観測情報 \mathbf{o}_{t+1} を以下の式により更新する.

$$\mathbf{o}_{t+1} = \mathbf{o}_t + (\bar{\mathbf{a}}_t^{(1)} + \bar{\mathbf{a}}_t^{(2)}) \Delta t \quad (13)$$

Δt は 1 フレームの間隔である.

4. 実験

本実験では, 提案する TS-IOHMM が運転行動を的確にモデル化できるか評価するため, 以下の 3 つの評価・分析を行った. まず, TS-IOHMM を用いて車両速度を予測したときの精度を評価した (4.3 節). 行動の安全性や円滑さを考えるうえでは各時刻での車両の位置が重要なため, 予測した車両速度をもとに各時刻での車両の位置を算出し, その誤差を精度評価に用いた. 次に, 提案モデルにより獲得された行動ルールを明確にするため, 提案モデルの潜在変数とその状態遷移がどのような運転者の内部状態と解釈できるかを分析した (4.4 節). 最後に, 正しく行動ルールを獲得したか評価するため, 評価用データの行動ルールと提案モデルが獲得した行動ルールを比較した (4.5 節).

TS-IOHMM のパラメータの学習と精度評価のため, 車両と歩行者が交差するシーンについて, 様々な位置や速度で行動する車両と歩行者のデータが必要である. また, 評価用データの運転者の行動ルールが必要である. 本実験ではシミュレーションによるデータ生成により, 学習用データと評価用データを用意する. 車両や歩行者の位置や速度を任意に設定できるため, 多様な状況下で車両や歩行者の行動のデータを得ることができる.

以下に, 使用するデータや実験設定, 実験環境を説明した後, 実験結果とその考察を述べる.

4.1 シミュレーションによるデータ生成

実験に必要なデータは, 道路を直進する車両とその前方を横断する歩行者が垂直に交差する状況 (図 2) における, 各時刻の車両の位置, 歩行者の位置, 車両の速度, 歩行者の速度である. これらを, モデルのパラメータ学習用と性能評価用データとしてそれぞれ生成する.

Yang らが提案した車両と歩行者の行動モデル [19] を用いて, 実験に必要なデータを生成した. Yang らの歩行者の行動モデルは, 歩行者が 5 種類の状態を切り替えながら, Social Force モデルに基づいて動き, 道路を横断する. 各状




図2 シミュレーションする交通シーン
Fig. 2 Simulated traffic scene.

態で Social Force の計算式が異なり、生成される歩行者の動きも異なる。Social Force は、目的地に到達しようとする destination force と車両からの影響である vehicle effect force の和で表され、車両の行動から歩行者への影響が考慮されている。車両の行動モデルは、歩行者の動きを予測して加減速の操作を決定する Model Predictive Control を用いる。歩行者とつねに一定以上の間隔を保つよう動きが生成され、歩行者の行動から運転者への影響が考慮されている。

Yang らのシミュレーション [20] を使用し、車両と歩行者をそれぞれのモデルに従って動かし、データを生成した。シミュレーションでは、車両と歩行者はそれぞれ直進して垂直に交差するものとし、車両の進行方向に x 軸、歩行者の進行方向に y 軸をとり、車両と歩行者の軌跡が交差する点を原点 O とする座標系を用いた。車両の初期位置と初期速度、歩行者の初期位置と初期速度は後述するように与え、それ以外の各パラメータは Yang らが設定した値を用いた。車両の初期位置を $(L_c, 0)$ 、歩行者の初期位置を $(0, L_p)$ とする。車両の初期速度を V_c [m/s]、歩行者の初期速度を V_p [m/s] とする。車両と歩行者に様々なパターンの行動をさせるため、車両と歩行者の初期位置や初期速度を変化させた。現実での交通環境を考慮し、それぞれの初期位置は下記の範囲から無作為に決めた。

$$\begin{aligned} -50.0 \text{ [m]} \leq L_c \leq -30.0 \text{ [m]} \\ -4.0 \text{ [m]} \leq L_p \leq -2.0 \text{ [m]} \end{aligned} \quad (14)$$

また、それぞれの初期速度は以下の確率分布を用いて決めた。

$$\begin{aligned} p(V_c) &= \mathcal{N}(8.0, 1.0) \\ p(V_p) &= \mathcal{N}(1.4, 0.2) \end{aligned} \quad (15)$$

シミュレーションでは、現実的な挙動をするための物理的な制約を設定した。以下に説明する物理的な制約は、シミュレーションを開発した Yang ら [19] が制約したものであり、本稿の想定する交通シーンにも適切な制約と考えたため利用した。歩行者は、一般的な歩行速度を想定し、最大速度 2.5 [m/s]、最大加速度 5.0 [m/s²] に制約した。車両は、速度変化が現実的な急加速・急ブレーキの範囲に収まるよう、速度が 0.0 [m/s]~ 22.5 [m/s]、加速度が -7.0 [m/s²]~ 7.0 [m/s²]、加速度の変化量(加加速度)が -5.0 [m/s³]~ 5.0 [m/s³] の範囲に制約した。また、歩行者と車両がつね

に保つ間隔を 3 m 以上と設定した。これにより、車両は歩行者の 3 [m] 以上手前で停車できるよう加減速が制御され、シミュレーションにおいて車両と人が衝突することを防いでいる。歩行者に対し間隔に余裕を持って停車することは、現実に見られる行動と考えられる。これらの物理制約の各値(パラメータ)は、シミュレーションのデフォルト値 [20] を採用したが、本稿の想定する交通シーンにも適切であったため利用した。

以上のようにして、学習用に 500 系列、評価用に 100 系列のデータを生成した。

4.2 実験設定・実験環境

評価用データの各系列に対し、開始から 2 秒間 (20 フレーム) の観測情報と歩行者や車両の速度が得られたとして、提案モデルを用いて系列に沿って各時刻の車両速度を順に予測し、系列の終端までの速度を予測する実験を行った。これを 100 回繰り返し、各時刻で 100 試行の予測結果を平均して得られる速度系列を、最終的な予測結果とした。

精度評価では、予測した車両速度をもとに算出した各時刻での予測位置と正解位置との誤差を評価する。評価指標として、各時刻での車両の位置の誤差(ユークリッド距離)の平均である Average Displacement Error (ADE) と、系列の終端時点での車両の位置の誤差である Final Displacement Error (FDE) を用いた。それぞれの指標について、全系列での平均を評価した。

潜在変数 $\mathbf{x}_t^{(1)}$ および $\mathbf{x}_t^{(2)}$ の状態数はそれぞれ $s_1 = 4$, $s_2 = 6$ とした。本手法では潜在変数に応じた正規分布に従って出力変数(速度)が決定される。そのため状態数は、速度をどの程度細かく制御できるかを表すといえる。状態数が小さい場合、たとえば状態数が 2 では、モデルは走行中か停止中か程度の表現しかできない。一方で、モデルの表現力を越えるほど状態数を大きくすることも不適切である。歩行者は速度を細かく制御できるが、大きな速度は出せないのとおり速度域は狭い。車両はとりうる速度域は広いが、歩行者ほど細かくは制御できない。これらの点を考慮し、予備実験として状態数を変化させて車両速度の予測を行い、そこで良い予測精度が得られたときの結果をもとに、潜在変数の状態数を設定した。この予備実験では学習用のシミュレーションデータのみを用いた。また、入力変数 $i_t^{(1)}$ および $i_t^{(2)}$ のクラスタ数は、潜在変数の状態数の決定と同様に、予備実験としてクラスタ数を変化させて車両速度の予測を行い、そこで良い予測精度が得られたときの結果をもとに、それぞれ $\kappa_1 = 10$, $\kappa_2 = 10$ とした。各クラスタの代表点 $\mathbf{m}^{(1)}$, $\mathbf{m}^{(2)}$ は、学習用データに k -means 法を適用して求めた。

4.3 予測精度の評価

提案モデルの予測精度の評価のため、IOHMM と比較し

表 1 車両速度予測精度評価の結果

Table 1 Results of evaluating prediction accuracy.

Method	ADE [m]	FDE [m]
TS-IOHMM (Proposed)	2.54	5.17
IOHMM	4.13	10.39

た. IOHMM は, 観測した歩行者の行動をもとに運転者の内部状態が変化し, それに基づいて車両速度が決定する過程を表現する. 多くの既存手法 [2], [4] のもとになったモデルである. IOHMM は, 運転者が受ける影響は考慮するが, 歩行者が受ける影響は考慮しない. すなわち, 車両がどのような行動をしたとしても, 歩行者が行動を変えないことを前提とする. 予測時, 将来の歩行者の位置や速度は, 過去の歩行者速度系列から平均加速度を算出し, 等加速度で移動すると仮定して算出したものを用いる.

各手法の精度評価結果を表 1 に示す. 表から分かる通り, TS-IOHMM の誤差が小さく, 良い性能を示した. IOHMM は, 歩行者との位置関係や速度を考慮したモデルだが, 予測性能は低下した. これは, 歩行者が車両の行動次第で次に停止するか移動するかを選択するような行動の変化を考慮していないためと考えられる. IOHMM には, 歩行者の内部状態がないので, 停止した歩行者は停止し続け, 移動する歩行者は移動し続けるものとして車両速度を予測する. これにより, IOHMM が誤った歩行者の速度系列を入力して車両速度を予測することになり, かえって精度が低下したと考えられる. これに対し, TS-IOHMM は歩行者からの影響だけでなく, 車両の行動から歩行者の内部状態への影響を考慮して車両速度を予測するので, 良い精度を示したと考えられる.

本稿で想定するシーンでは, 「車両と歩行者が衝突しないこと」が重要なため, 両者が衝突する誤差は許容できない. 今回使用したシミュレーションデータでは, 車両は歩行者と 3m 以上距離を空けて停止する制約としたため, 車両と人が最も近い状況は 3m の距離と想定される. そのため, 3m 以上の誤差では衝突する可能性がある. 表 1 を見ると, TS-IOHMM の ADE が 2.54m であり, 全系列の平均では誤差は 3m 以内である. しかし, 個々の系列の誤差は 3m を超える場合もあったため, 予測精度の改善は今後の課題である.

4.4 TS-IOHMM が獲得した行動ルール

TS-IOHMM は潜在変数 $x_t^{(2)}$ の遷移によって運転者の内部状態を表現している. ここでは, 実際に TS-IOHMM がどのような運転者の内部状態を表現しているかを分析して, 獲得した行動ルールについて考察する.

車両速度である出力変数 $a_t^{(2)}$ は, 式 (6) に示したように, 潜在変数 $x_t^{(2)}$ に応じた正規分布によって決定される. 本実験で求められた正規分布のパラメータ (平均 $\mu_j^{(2)}$ と共

表 2 学習後の TS-IOHMM のパラメータ

Table 2 Parameters of TS-IOHMM after training.

$\arg \max_j x_{t,j}^{(2)}$	1	2	3	4	5	6
$\mu_j^{(2)}$	5.36	6.61	7.33	7.87	8.37	9.16
$\Sigma_j^{(2)}$	0.503	0.059	0.034	0.022	0.023	0.239

表 3 遷移行列の例 (加速)

Table 3 Example of transition matrix (acceleration).

	$\arg \max_j x_{t,j}^{(2)}$						
	1	2	3	4	5	6	
$\arg \max_j x_{t-1,j}^{(2)}$	1	0.896	0.100	0.001	0.001	0.001	0.001
	2	0.001	0.928	0.068	0.001	0.001	0.001
	3	0.001	0.001	0.940	0.056	0.001	0.001
	4	0.001	0.001	0.001	0.949	0.047	0.001
	5	0.001	0.001	0.001	0.001	0.955	0.041
	6	0.001	0.001	0.001	0.001	0.001	0.995




図 3 状態遷移の例 (加速)

Fig. 3 Example of state transitions representing the acceleration.

分散 $\Sigma_j^{(2)}$ を表 2 に示す. ここで, $\arg \max_j x_{t,j}^{(2)}$ は $x_t^{(2)}$ の値を 1~6 のスカラー値で表現したものである. $x_t^{(2)}$ の値によって正規分布の平均 $\mu_j^{(2)}$ が異なるので, $x_t^{(2)}$ が遷移することで出力される車両速度が変化する. $x_t^{(2)}$ は, 遷移確率 $\omega_{jkc}^{(2)} \equiv p(x_{t,k}^{(2)} = 1 | x_{t-1,j}^{(2)} = 1, c = f(i_t^{(2)}))$ に従って遷移する. $\omega_{jkc}^{(2)}$ は, 入力変数 $i_t^{(2)}$ が属するクラス c に依存する. 本実験設定ではクラス数 $\kappa_2 = 10$ であるから, TS-IOHMM は 10 個の遷移行列を持つ. 本実験で得られた 10 個の遷移行列のうちの 1 個を表 3 に示す. 表中の数値は前状態 $x_{t-1}^{(2)}$ から次状態 $x_t^{(2)}$ への遷移確率を示している. 自己遷移の確率が高いのは車両速度が急激に変化しないためであり, 自己遷移以外の遷移確率が重要である.

潜在変数の遷移がより分かりやすくなるよう, 状態遷移を図で表現した. 表 3 に対応する状態遷移を図 3 に示す. 図中の頂点が各状態を示し, 頂点内の数値は $\arg \max_j x_{t,j}^{(2)}$ の値を示す. この値は表 2 と対応している. 図中の有向辺の太さは遷移確率の大きさを表す. 有向辺の太さは (0.001, 0.010], (0.010, 0.100], (0.100, 1.000) の 3 段階で, 有向辺が太いほど遷移確率が大きい. 遷移確率が微小 (0.001 以下) な遷移は無視できると考えられるため, 有向辺は表記していない. 図 3 では, 基本的には自己遷移をするが, 徐々に状態の数値が小さい方から大きい方へと遷移するよ

表 4 遷移行列の例 (減速)

Table 4 Example of transition matrix (deceleration).

	$\arg \max_j x_{t,j}^{(2)}$						
	1	2	3	4	5	6	
$\arg \max_j x_{t-1,j}^{(2)}$	1	0.995	0.001	0.001	0.001	0.001	0.001
	2	0.031	0.966	0.001	0.001	0.001	0.001
	3	0.001	0.094	0.902	0.001	0.001	0.001
	4	0.001	0.001	0.153	0.843	0.001	0.001
	5	0.001	0.001	0.001	0.184	0.812	0.001
	6	0.001	0.001	0.001	0.001	0.153	0.843

表 5 遷移行列の例 (速度維持)

Table 5 Example of transition matrix (keeping speed).

	$\arg \max_j x_{t,j}^{(2)}$						
	1	2	3	4	5	6	
$\arg \max_j x_{t-1,j}^{(2)}$	1	0.995	0.001	0.001	0.001	0.001	0.001
	2	0.001	0.992	0.004	0.001	0.001	0.001
	3	0.001	0.001	0.992	0.004	0.001	0.001
	4	0.001	0.001	0.001	0.985	0.011	0.001
	5	0.001	0.001	0.001	0.001	0.955	0.007
	6	0.001	0.001	0.001	0.001	0.001	0.995




図 4 状態遷移の例 (減速)

Fig. 4 Example of state transitions representing the deceleration.




図 5 状態遷移の例 (速度維持)

Fig. 5 Example of state transitions representing speed keeping.

うな状態遷移が見られる。各状態の正規分布のパラメータ (表 2) を加味すると、徐々に高い車両速度を出力する状態に遷移することから、この状態遷移は「加速」を表現していると解釈することができる。同様に、他の遷移行列を分析すると、大きく分けて「加速」「減速」「速度維持」の 3 種類の状態遷移が見られた。表 4 と表 5 に残り 2 種類の遷移行列の 1 例を示し、それぞれに対応する状態遷移を図 4、図 5 に示す。図 4 は徐々に低い車両速度を出力する状態に遷移することから「減速」を、図 5 は自己遷移以外の遷移確率が小さく同じ状態が継続することから「速度維持」を、それぞれ表現していると解釈することができる。10 個

表 6 学習後の TS-IOHMM のパラメータ (歩行者)

Table 6 Parameters of TS-IOHMM after training.

$\arg \max_j x_{t,j}^{(1)}$	1	2	3	4
$\mu_j^{(1)}$	-0.001	0.77	1.26	1.50
$\Sigma_j^{(1)}$	0.000	0.259	0.006	0.008

の遷移行列のうち、3 個の遷移行列は「加速」に、2 個の遷移行列は「減速」に、5 個の遷移行列は「速度維持」に分類される遷移行列であった。以上のことから、TS-IOHMM の潜在変数とその遷移によって、加減速が表現できていることが確認できた。

次に、各遷移行列が適用される状況を分析した。図 3 の加速を表す遷移行列が使用されるクラスタの代表点は、車両の位置が (-4.1, 0)、歩行者の位置が (0, 4.2)、歩行者速度が 1.49 であった。これは歩行者が横断した後の状況である。図 4 の減速を表す遷移行列が使用されるクラスタの代表点は、車両の位置が (-33.6, 0)、歩行者の位置が (0, -2.0)、歩行者速度が 1.27 で、これは歩行者が道路へ接近中の状況であった。図 5 の速度維持を表す遷移行列が使用されるクラスタの代表点は、車両の位置が (16.0, 0)、歩行者の位置が (0, 1.6)、歩行者速度が 1.38 で、これは車両と歩行者の両者が通過し終えた後の状況であった。それぞれの遷移行列が使用されるクラスタの代表点をもとに、各種の状態遷移とそのときの状況をまとめると、以下の行動ルールが見られた。

- 歩行者が横断した後 (車両が歩行者の横を通過する前) に加速する。
- 歩行者が道路脇で停止しているときに加速する。
- 歩行者が横断する前で、車両が交差点に近いときに加速する。
- 歩行者が横断前のときに減速する。
- 車両と歩行者の両者が通過した後に速度維持する。

以上が、TS-IOHMM の潜在変数の遷移によって表現された運転者の内部状態の変化であり、モデルによって獲得された運転者の行動ルールと解釈できる。

また、歩行者の行動ルールについて考察する。歩行者速度である出力変数 $\mathbf{a}_t^{(1)}$ は、潜在変数 $\mathbf{x}_t^{(1)}$ に応じた正規分布によって決定される。本実験で求められた正規分布のパラメータを表 6 に示す。表 6 を見ると、学習後のパラメータ $\mu_1^{(1)} \doteq 0$ であることから、この状態 ($\arg \max_j x_{t,j}^{(1)} = 1$) は歩行者の停止と解釈することができる。次に、遷移行列の例を表 7、表 8、表 9 に示す。これらの状態遷移を分析すると、運転者のときと同様に、大きく分けて「加速」「減速」「速度維持」の 3 種類の状態遷移が見られ、10 個の遷移行列はそれぞれ 3 種類のいずれかに分類できた。これにより、潜在変数とその遷移によって加減速が表現できていることが確認できた。表 9 の遷移行列は「速度維持」と解釈した

表 7 遷移行列の例 (加速) (歩行者)

Table 7 Example of transition matrix (acceleration) in the case of pedestrian.

		$\arg \max_j x_{t,j}^{(1)}$			
		1	2	3	4
$\arg \max_j x_{t-1,j}^{(1)}$	1	0.934	0.064	0.001	0.001
	2	0.011	0.714	0.274	0.001
	3	0.001	0.001	0.606	0.392
	4	0.001	0.001	0.001	0.997

表 8 遷移行列の例 (減速) (歩行者)

Table 8 Example of transition matrix (deceleration) in the case of pedestrian.

		$\arg \max_j x_{t,j}^{(1)}$			
		1	2	3	4
$\arg \max_j x_{t-1,j}^{(1)}$	1	0.997	0.001	0.001	0.001
	2	0.001	0.986	0.008	0.005
	3	0.001	0.097	0.901	0.001
	4	0.001	0.001	0.068	0.930

表 9 遷移行列の例 (速度維持) (歩行者)

Table 9 Example of transition matrix (keeping speed) in the case of pedestrian.

		$\arg \max_j x_{t,j}^{(1)}$			
		1	2	3	4
$\arg \max_j x_{t-1,j}^{(1)}$	1	0.233	0.260	0.264	0.242
	2	0.001	0.997	0.001	0.001
	3	0.001	0.001	0.997	0.001
	4	0.001	0.001	0.001	0.997

例だが、自己遷移の確率が高いのは $\arg \max_j x_{t,j}^{(1)} \geq 2$ のときで、歩行者が歩いている状況に限定される「速度維持」である。停止のときも速度維持する（停止し続ける）ならば、 $\arg \max_j x_{t,j}^{(1)} = 1$ のときの自己遷移の確率が高くなる。この遷移行列が適用されるのは歩行者の位置が道路上のときである。歩行者が道路上で停止することは危険であり、停止するのは道路脇のみであるため、「同じ速度で歩き続ける」状況と「停止し続ける」状況が異なり、表 9 のように歩いている状況の「速度維持」が学習されたと考えられる。

各遷移行列が適用される状況をまとめると、以下の歩行者の行動ルールが見られた。

- 歩行者が道路脇に接近するときに減速する。
- 歩行者が道路脇にいるとき、車両の位置と速度に応じて減速または加速する。
- 車両が通過した後で、歩行者が横断前のときに加速する。
- 歩行者が道路上にいるときに速度維持する。

2 個目のルールについては、減速を表す遷移行列のクラスターの代表点が車両の位置 $(-21.8, 0)$ 、歩行者の位置 $(0, -0.97)$ 、




図 6 TS-IOHMM とシミュレーションの加減速パターンの比較 (1)

Fig. 6 Comparison between acceleration transitions of TS-IOHMM and simulation data (1).

車両速度 6.81、加速を表す遷移行列のクラスターの代表点が車両の位置 $(-17.7, 0)$ 、歩行者の位置 $(0, -0.71)$ 、車両速度 5.46 であり、この中間を境に加速と減速が変わるルールが見られた。

4.5 獲得した行動ルールの評価

TS-IOHMM が獲得した行動ルールと評価用データの行動ルールを比較し、提案モデルが適切に行動ルールを獲得できたか評価した。2つの行動ルールは表現方法が異なり直接比較することができないので、ここではそれぞれの行動ルールから生成される内部状態をもとに比較を行った。4.4 節で述べたように、TS-IOHMM は適用される遷移行列によって加速、減速、速度維持の 3 状態に分類される。各時刻で適用される遷移行列を時系列に見ていくことで、TS-IOHMM の獲得した行動ルールから生成される加減速の変化（以下、加減速パターン）を得ることができる。一方、評価用データの場合、Yang らのシミュレーションには車両速度制御用の計算モデルがあり、加速度に相当する値（論文中では control action と呼ばれる値）を算出することで、加減速が決定される。この計算モデルが行動ルールに相当するので、そこから生成された加減速パターンを比較用として用いた。control action は連続値のため、比較の際は適当な閾値処理によって加速、減速、速度維持に分類した加速度パターンを用いた。

まず、TS-IOHMM がうまく車両速度を予測した系列の 1 例について、TS-IOHMM と評価用データ（シミュレーション）の加減速パターンを比較した結果を図 6 に示す。図中の青色の実線が TS-IOHMM の加減速パターン、赤色の破線がシミュレーションの加減速パターンを表す。また、シミュレーションの加減速パターンのもとになった control action の値を赤色の点線で示した。図 6 の系列では、シミュレーションの加減速パターンとほぼ同等の加減速パターンを TS-IOHMM が出力した。次に、TS-IOHMM が車両速度を予測した系列の別の 1 例について、比較結果を図 7 に示す。図 7 の系列では、「減速」から「加速」に切り替わるまでの加減速パターンはシミュレーションと同等




図 7 TS-IOHMM とシミュレーションの加減速パターンの比較 (2)

Fig. 7 Comparison between acceleration transitions of TS-IOHMM and simulation data (2).

であるが、その後の「加速」の区間が長い加減速パターンを TS-IOHMM が出力した。TS-IOHMM では、適用される「加速」の遷移行列から「速度維持」の遷移行列に変わることによって、「加速」から「速度維持」に切り替わる。適用される遷移行列は入力変数（車両と歩行者の位置、歩行者の速度）の属するクラスタにより決まるため、両者が接近したことで属するクラスタが変化したが、図 7 の切り替わりのタイミングだった。このタイミングが遅れた原因は、TS-IOHMM では適用する遷移行列を入力変数の値に基づき離散的に切り替えるのに対し、シミュレーションでは加速から速度維持が連続的に変化する（図 7 中の control action を参照）ためと考えられる。本手法では加減速の切り替えが離散的な表現のため、このように加減速の切り替わりをうまく予測できないことがある。また、図 3 の状態遷移図を見ると、TS-IOHMM の「加速」は、最も高い速度帯を出力する状態 ($\arg \max_j x_{t,j}^{(2)} = 6$) では自己遷移のみで他状態へ遷移しない。これは「速度維持」の遷移行列と同じであり、車両速度が高い状態では「加速」と「速度維持」が同様の出力が見られる。

まとめると、図 6 の系列のように、TS-IOHMM がシミュレーションと同等の加減速パターンを出力していることから、評価用データにとって適切な行動ルールを獲得できたと考えられる。本実験では、TS-IOHMM の遷移行列が表す行動ルールを「加減速」と解釈したが、各時刻に注目すれば、TS-IOHMM は入力と前状態に基づいて車両速度を出力する。前状態は直前の車両速度に関係するので、状況と直前の車両速度から次の車両速度を出力していることになる。したがって、TS-IOHMM は「目標速度」を学習していると解釈することもできる。しかし、時系列で注目すれば、TS-IOHMM は入力と遷移行列に応じた状態遷移を行って車両速度系列を出力する。状況に応じて加速や減速、速度維持の速度系列が出力できていることから、TS-IOHMM は「加減速」を学習していると解釈できる。特に学習された遷移行列に注目すると、図 3 や図 4 のように加速や減速と解釈できる状態遷移が見られたことから、本稿では「加減速」を学習していると解釈した。

5. おわりに

本稿では、自動車と歩行者が交差するシーンを対象として、車両歩行者間のインタラクティブな行動ルールの獲得を目指し、運転行動をモデル化するための 2 段階入出力隠れマルコフモデル (TS-IOHMM) を提案した。TS-IOHMM は、運転者や歩行者の内部状態を表現する HMM をもとに構成され、運転者が歩行者の行動を予測したうえで運転行動を決定するようなインタラクティブな行動ルールをモデル化した。シミュレーションデータを用いた実験により、運転行動の予測精度を評価することで比較手法と比べて TS-IOHMM のモデル構造が当該シーンの運転行動を表現できたことを示した。また、TS-IOHMM の潜在変数の遷移を分析することで、TS-IOHMM が大きく分けて 3 種類の加減速に関わる行動ルールを獲得したことを明らかにした。最後に、TS-IOHMM が出力する加減速パターンがシミュレーションの加減速パターンとほぼ同等であることを示し、TS-IOHMM が適切に行動ルールを獲得できていることを示した。

今後は、実環境での自動車と歩行者の交差シーンのデータを用いて運転行動をモデル化し、同様に運転者の行動ルールを獲得することを目指す。また、実環境では車両と歩行者の位置や速度だけでなく、様々な要因のもとに行動予測が行われる。特に歩行者に関しては、様々な場面に対応するために歩行者の属性情報が重要になると考えられ、今後は歩行者属性を考慮した運転行動のモデル化を検討していきたい。


謝辞 本研究の一部は国立研究開発法人科学技術振興機構 (JST) の研究成果展開事業「センター・オブ・イノベーションプログラム (名古屋 COI)」および、JSPS 科研費 (17H00745) による。

参考文献

- [1] 長田悠吾, 石川 悟, 大森隆司, 森川幸治: 意図推定に基づく行動決定戦略の動的選択による協調行動の計算モデル化, 認知科学, Vol.17, No.2, pp.270–286 (2010).
- [2] Akai, N., Hirayama, T., Morales, L.Y., Akagi, Y., Liu, H. and Murase, H.: Driving Behavior Modeling Based on Hidden Markov Models with Driver’s Eye-Gaze Measurement and Ego-Vehicle Localization, *Proc. 2019 IEEE Intelligent Vehicles Symposium*, pp.949–956 (2019).
- [3] Alahi, A. Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L. and Savarese, S.: Social LSTM: Human Trajectory Prediction in Crowded Spaces, *Proc. 2016 IEEE Conference on Computer Vision and Pattern Recognition*, pp.961–971 (2016).
- [4] Blaiotta, C.: Learning Generative Socially-Aware Models of Pedestrian Motion, *IEEE Robotics and Automation Letters*, Vol.4, No.4, pp.3433–3440 (2019).
- [5] Brand M., Oliver N. and Pentland A.: Coupled Hidden Markov Models for Complex Action Recognition, *Proc. 1997 IEEE Conference on Computer Vision and Pattern Recognition*, pp.994–999 (1997).


- [6] Bishop, C.M.: *Pattern Recognition and Machine Learning*, Springer (2006).
- [7] Dan, N.V. and Kameyama, M.: Bayesian-Networks-Based Motion Estimation for a Highly-Safe Intelligent Vehicle, *Proc. 2006 SICE-ICASE International Joint Conference*, pp.6023-6026 (2006).
- [8] Dong, C., Dolan, J.M. and Likouhi, B.: Intention Estimation for Ramp Merging Control in Autonomous Driving, *Proc. 2017 IEEE Intelligent Vehicles Symposium*, pp.1584-1589 (2017).
- [9] He, L., Zong, C.-F. and Wang, C.: Driving Intention Recognition and Behaviour Prediction based on a Double-Layer Hidden Markov Model, *Journal of Zhejiang University SCIENCE C*, Vol.13, No.3, pp.208-217 (2012).
- [10] Helbing, D. and Molnár, P.: Social Force Model for Pedestrian Dynamics, *Physical Review E*, Vol.51, No.5, pp.4282-4286 (1995).
- [11] Hou, H., Jin, L., Niu, Q., Sun, Y. and Lu, M.: Driver Intention Recognition Method Using Continuous Hidden Markov Model, *International Journal of Computational Intelligence Systems*, Vol.4, No.3, pp.386-393 (2011).
- [12] Jain, A., Koppula, H.S., Raghavan, B., Soh, S. and Saxena, A.: Car that Knows Before You Do: Anticipating Maneuvers via Learning Temporal Driving Models, *Proc. 2015 IEEE International Conference on Computer Vision*, pp.3182-3190 (2015).
- [13] 川嶋宏彰, 松山隆司: ハイブリッドダイナミカルシステムによる動的現象のモデル化と認識 (特集) ダイナミクスに基づく情報処理の諸相, システム/制御/情報, Vol.54, No.1, pp.28-33 (2010).
- [14] Kooij, J.F.P., Schneider, N., Flohr, F. and Gavrila, D.M.: Context-Based Pedestrian Path Prediction, *Computer Vision - ECCV 2014*, pp.618-633 (2014).
- [15] 押川 慧, 中村友昭, 長井隆行, 岩橋直人, 船越孝太郎, 中野幹生, 金子正秀: Coupled GP-HSMM を用いた連続動作の分節化に基づくインタラクションのモデル化, 人工知能学会全国大会論文集, 4L204 (2018).
- [16] Rasouli, A., Kotseruba, I., Kunic, T. and Tsotsos, J.K.: PIE: A Large-Scale Dataset and Models for Pedestrian Intention Estimation and Trajectory Prediction, *Proc. 2019 IEEE International Conference on Computer Vision*, pp.6262-6271 (2019).
- [17] Rasouli, A. and Tsotsos, J.K.: Autonomous Vehicles that Interact with Pedestrians: A Survey of Theory and Practice, *IEEE Trans. Intelligent Transportation Systems*, Vol.21, No.3, pp.900-918 (2020).
- [18] Wu, H., Wang, L., Zheng, S., Xu, Q. and Wang, J.: Crossing-Road Pedestrian Trajectory Prediction Based on Intention and Behavior Identification, *Proc. 2020 IEEE Intelligent Transportation Systems Conference*, pp.3005-3010 (2020).
- [19] Yang, D., Redmill, K. and Ozguner, U.: A Multi-State Social Force Based Framework for Vehicle-Pedestrian Interaction in Uncontrolled Pedestrian Crossing Scenarios, *Proc. 2020 IEEE Intelligent Vehicles Symposium*, pp.1807-1812 (2020).
- [20] Yang, D.: Vehicle-Pedestrian Interaction (VPI) in Crossing Scenarios, available from (<https://github.com/dongfang-steven-yang/vpi-crossing>) (accessed 2021-08-17).
- [21] Kim, K., Lee, Y.K., Ahn, H., Hahn, S. and Oh, S.: Pedestrian Intention Prediction for Autonomous Driving Using a Multiple Stakeholder Perspective Model, *Proc. 2020 IEEE/RSJ International Conference on Intelli-*

- gent Robots and Systems (IROS)*, pp.7957-7962 (2020).
- [22] 独立行政法人自動車事故対策機構: 自動車アセスメントのご案内, 入手先 (<https://www.nasva.go.jp/mamor/about/about.html>) (参照 2022-04-04).



新村 文郷

2013年静岡大学創造科学技術大学院博士後期課程修了。博士(情報学)。同年名古屋大学大学院情報科学研究科研究員。2014年同大学未来社会創造機構研究員。2019年同大学大学院情報学研究科研究員。2021年より成蹊大学理工学部助教。現在に至る。画像処理・パターン認識技術のITS応用の研究に従事。電子情報通信学会会員。



赤井 直紀

2016年宇都宮大学大学院システム創成工学専攻博士後期課程修了。博士(工学)。同年名古屋大学未来社会創造機構特任助教, 2019年同大学大学院情報学研究科特任助教。2020年より同大学院工学研究科助教, 現在に至る。車輪型移動ロボットおよび自動車の自動走行, 特に自己位置推定に関する研究に従事。SII2013 Best Student Paper Award, JSAE2018 秋季大会優秀講演発表賞等を受賞。IEEE, SICE, RSJ, JSME 各会員。



平山 高嗣 (正会員)

2005年大阪大学大学院基礎工学研究科博士後期課程修了。博士(工学)。同年京都大学大学院情報学研究科特任助教。2011年名古屋大学大学院情報科学研究科特任助教, 2012年同助教, 2014年同特任准教授。2017年名古屋大学未来社会創造機構特任准教授。2021年より人間環境大学人間環境学部環境科学科教授。現在に至る。画像認識, 視行動分析, 視覚的注意の計算モデルに関する研究に従事。IEEE ISM2014 Best Paper Award, 2014年電子情報通信学会情報・システムサイエティ論文賞等受賞。IEEE, 電子情報通信学会, ACM 各会員。



劉 海龍

2018年立命館大学大学院情報理工学研究科博士後期課程修了。博士（工学）。2016～2018年日本学術振興会特別研究員（DC2）。同年、名古屋大学未来社会創造機構研究員。2019年同大学大学院情報学研究科研究員。2021

年より奈良先端科学技術大学院大学情報科学領域特任助教，現在に至る。歩行者と自動運転車両のインタラクション，自動運転に対する過剰信頼，動揺病等の課題に関する研究に従事。IEEE IV2015 Best Student Paper Award, IEEE GCCE2016 Outstanding Paper Award, 計測自動制御学会2018年システム・情報部門 SSI 優秀発表賞等受賞。IEEE, 計測自動制御学会, 自動車技術会各会員。



村瀬 洋（正会員）

1980年名古屋大学大学院修士課程修了。同年日本電信電話公社（現NTT）入社。1992年より1年間米国コロンビア大学客員研究員。2003年名古屋大学大学院情報科学研究科教授。2017年同大学院情報学研究科教授。2021

年より同大学院情報学研究科名誉教授・特任教授，現在に至る。文字・図形認識，コンピュータビジョン，マルチメディア認識の研究に従事。工学博士。1994年IEEE-CVPR最優秀論文賞，1995年情報処理学会山下記念研究賞，1996年IEEE-ICRA最優秀ビデオ賞，2002年電子情報通信学会業績賞，2003年文部科学大臣賞，2004年IEEE Trans. MM論文賞，2010年前島密賞，2012年紫綬褒章，他受賞。IEEEフェロー，電子情報通信学会フェロー。本会フェロー。



川西 康友

2012年京都大学大学院情報学研究科博士後期課程修了。博士（情報学）。同年同大学学術情報メディアセンター特定研究員。2014年名古屋大学未来社会創造機構特任助教。2015年同大学大学院情報科学研究科助教。2017

年同大学院情報学研究科助教，2020年同講師。2021年より理研 GRP 感覚データ認識研究チームチームリーダー。現在に至る。ロボットによる周囲環境認識および，人物追跡・属性認識・行動認識等の人物画像処理に関する研究に従事。2011年度PRMU研究奨励賞受賞。IEEE ITS Society Nagoya Chapter Young Researcher Award 受賞。IEEE, 画像電子学会, 電子情報通信学会各会員。



出口 大輔（正会員）

2006年名古屋大学大学院情報科学研究科博士後期課程修了。博士（情報科学）。2004～2006年日本学術振興会特別研究員。2006年名古屋大学大学院情報科学研究科研究員，同大学院工学研究科研究員，2008～2012年同大学

院情報科学研究科助教，2012年同大学情報連携統括本部情報戦略室准教授，2020年同大学大学院情報学研究科准教授。現在に至る。主に画像処理・パターン認識技術の開発とそのITSおよび医用応用に関する研究に従事。2006年日本医用画像工学会奨励賞，2006年日本コンピュータ外科学会講演論文賞等受賞。IEEE, 電子情報通信学会各会員。