歩行者挙動モデルのパラメータ推定への 一般状態空間モデルの適用

中西 航¹・高橋 真美²・布施 孝志³

¹正会員 東京大学助教 大学院工学系研究科 社会基盤学専攻 (〒113-8656 東京都文京区本郷7-3-1)

E-mail: nakanishi@civil.t.u-tokyo.ac.jp

²非会員 東京大学 大学院工学系研究科 社会基盤学専攻 修士課程 (〒113-8656 東京都文京区本郷7-3-1)

E-mail: takahashi@trip.t.u-tokyo.ac.jp

³正会員 東京大学准教授 大学院工学系研究科 社会基盤学専攻 (〒113-8656 東京都文京区本郷7-3-1)

E-mail: fuse@civil.t.u-tokyo.ac.jp

本研究では、ミクロな歩行者挙動モデルのパラメータ推定手法としての一般状態空間モデルの適用可能性を検討する。この手法は、最尤推定に代表される従来手法にはない利点を有する。それは、逐次的に得られる挙動データに基づいて逐次的にパラメータ推定が可能であること、結果としてパラメータの時系列変化を捉えられること、取得されるデータの計測誤差を明示的にモデル化できることである。まず、一般状態空間モデルにおけるパラメータ推定を定式化する。次に、実データにより離散選択型の歩行者挙動モデルのパラメータ推定を行う。推定結果について、初期分布をはじめとする推定時の設定や、実際の歩行空間の状況との比較から考察を行い、この推定手法の有用性を実証的に示した。

Key Words : *pedestrian behavior model, parameter estimation, general state space model, particle filter, time series*

1. はじめに

近年、歩行者個々人の行動をモデル化したミクロシミュレーションモデルの構築が進んでいる¹⁾。そこでは、歩行者が自身の速度、周囲の歩行者や障害物から受ける影響などを明示的に変数として扱い、歩行者挙動を予測している。このとき、モデルおよびパラメータの推定は最尤推定によって行われることが多い。このことは、データ取得時間内における歩行者挙動は定常的である、すなわち、単一のモデルおよびパラメータで表現できるという仮定が暗に置かれていることを意味する。原理的にはモデルおよびパラメータの時間変化を考慮した尤度関数も設定可能だが、実際に行われることはまれである。尤度関数の次元数がタイムステップ数に応じて増加するため、尤度の最大化が困難となるからである。

他方で、現実の歩行空間においては、混雑度や各人物の進行方向などが時々刻々と変化している。歩行は自由度が高い複雑な挙動であるため、一つのモデルにこの変化を内包させて表現することは難しい。様々なモデルが提案され、説明変数も多種多様ある²⁾ものの、それらの説明変数が同一でも歩行者が異なる意思決定を行ってい

るようにみえる場合が少なからず存在する。この状況に対処するためには、歩行者の意思決定システムを包括的に表現できる単一のモデルおよびパラメータを探索するばかりではなく、モデルおよびパラメータが逐次変化していると捉えるアプローチも有用であろう。そこで本研究では、歩行者挙動の実データを逐次的に入手し、そのデータに基づいてモデルパラメータを逐次的に推定していく方法を考える。このような方法の必要性は、監視カメラから取得される画像情報や携帯電話に内蔵されたGPSセンサから取得される位置情報など、現実の歩行空間における歩行者挙動の実データが逐次的・大量に入手可能となるにつれて高まっていくであろう。また、逐次推定されるパラメータを解釈することで、将来的には準リアルタイムでの流動制御への応用可能性も見込まれる。この際に、多様なデータ取得手段が混在することを想定すると、計測誤差を明示的に扱える方法が望ましい。

以上の要件を満たすパラメータ推定手法として、本研究では一般状態空間モデルを利用した逐次ベイズ推定に着目する。後述するとおり、一般状態空間モデルを利用した推定においては、計測誤差を明示的に扱いながらパラメータを逐次ベイズ推定することができる。従って、

パラメータの時系列変化やデータの計測誤差を扱える推定方法として期待される．本研究では，これを歩行者挙動モデルのパラメータ推定に適用し，その有用性を実証的に示すことを目的とする．すなわち，歩行者挙動モデルの精度向上ではなく，大量データが逐次的に入手されることを想定した新たな推定手法の適用可能性を検討することを目的とする．

これまでに，セルオートマトン型の歩行者挙動モデルのパラメータ推定に一般状態空間モデルを適用している例²⁾は存在する．ただし，同モデルを用いたパラメータ推定の可能性について，推定時に分析者が行う複数の設定をもとに論じた研究は存在しない．これに対し，本研究は離散選択型の歩行者挙動モデルを推定対象に，以下を議論する．

- (a) パラメータ初期分布の推定結果への影響
- (b) パラメータの時系列変化と実現象との関係
- (c) パラメータの時系列変化の制御
- (d) データ計測精度と推定結果との関係

以下では，一般状態空間モデルによる歩行者挙動モデルのパラメータ逐次推定手法を説明する(2)．次いで，本研究における一般状態空間モデルの構成要素の設定を述べる(3)．この設定を，上記の(a)から(d)を議論すべく実挙動データに対して適用し，手法の有効性を確認するとともに，考察を行う(4)．

2. 一般状態空間モデルによるパラメータの逐次ベイズ推定方法

(1) 一般状態空間モデルと逐次ベイズ推定

本研究では，前述の通り一般状態空間モデル(図-1)を用いて歩行者挙動モデルのパラメータ推定を行う．一般状態空間モデルにおいては，観測した変量のベクトルを観測ベクトル $\mathbf{z}$ ，観測ベクトルを実現する観測不可能な変量のベクトルを状態ベクトル $\mathbf{x}$ としてそれぞれ定義する．そして，状態ベクトルの時間遷移を一次のマルコフ過程に従う条件付き分布であるシステムモデル $p(\mathbf{x}_t | \mathbf{x}_{t-1})$ ，状態ベクトルから観測ベクトルが生起する条件付き分布である観測モデル $p(\mathbf{z}_t | \mathbf{x}_t)$ をそれぞれモデル化する．また，状態ベクトルの初期分布 $p(\mathbf{x}_0)$ を別途モデル化する．

いま，データが逐次的に観測ベクトルとして取得できると想定する．このとき，一般状態空間モデルを用いて逐次的に時刻 t における状態ベクトル $\mathbf{x}_t$ を推定することを考える．その方法のひとつは，事後分布 $p(\mathbf{x}_t | \mathbf{z}_{1:t})$ を求めることである．この事後分布は，時刻1から t までの観測ベクトル $\mathbf{z}_{1:t} = \{\mathbf{z}_1, \mathbf{z}_2, \dots, \mathbf{z}_t\}$ が得られたならば，以下の式により推定できる³⁾．

図-1 一般状態空間モデル

$$p(\mathbf{x}_t | \mathbf{z}_{1:t}) \propto p(\mathbf{z}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{z}_{1:t-1}) \\ = p(\mathbf{z}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \quad (1)$$

右辺のうち $p(\mathbf{z}_t | \mathbf{x}_t)$ は観測モデルを， $p(\mathbf{x}_t | \mathbf{z}_{1:t-1})$ はシステムモデルを， $p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1})$ は時刻 $t-1$ における事後分布をそれぞれ示している．この式展開はベイズの法則に基づいていることから，本研究で推定される事後分布は，各時刻において状態ベクトルをベイズ推定した結果として得られる事後分布そのものである．また，時刻 $t-1$ における事後分布が時刻 t において事前分布として用いられることから，この推定を逐次ベイズ推定と呼ぶ．原理的に，ベイズ推定の推定結果は事後分布そのものであるが，これを解釈するための統計量としては以下が代表的である⁴⁾．

(a) 事後平均

事後平均とは，事後分布を推定したい値(本研究では状態ベクトルであり，以下でも同様に表記)で平均した値である．

$$\bar{\mathbf{x}}_t = \int \mathbf{x}_t p(\mathbf{x}_t | \mathbf{z}_{1:t}) d\mathbf{x}_t \quad (2)$$

(b) 事後モード

事後モードとは，事後分布の最大値を与える状態ベクトルの値である．事後確率最大化に基づく推定とも呼ぶ．

$$\hat{\mathbf{x}}_t = \arg \max_{\mathbf{x}_t} p(\mathbf{x}_t | \mathbf{z}_{1:t}) \quad (3)$$

(c) n パーセンタイル値

n パーセンタイル値は，事後分布の累積度数が n パーセントとなる状態ベクトルの値である．複数の n を設定すれば，区間推定としても用いることができる．

$$\hat{\mathbf{x}}_t \text{ such that } \int_{-\infty}^{\hat{\mathbf{x}}_t} p(\mathbf{x}_t | \mathbf{z}_{1:t}) d\mathbf{x}_t = \frac{n}{100} \quad (4)$$

なお，本研究での推定結果の考察においては，事後平均および25, 50, 75パーセンタイル値を使用する．

(2) 拡大状態ベクトルとパラメータ逐次最適化

上述の一般状態空間モデルを用いた逐次ベイズ推定を、歩行者挙動モデルのパラメータ推定に用いる方法を説明する。本研究においては、時刻 t において観測した歩行者位置を観測ベクトル $\mathbf{z}_t$ とする。これに対し、観測ベクトルに含まれる計測誤差を考慮し、直接観測することの出来ない、いわば真の歩行者位置を状態ベクトル $\mathbf{x}_t$ とする。このとき、システムモデルが歩行者挙動モデルに相当する。また、観測モデルはシステムモデルによる予測の誤差とデータ取得の計測誤差との和を表現する。この設定のもとでの式(1)の解釈は以下である。まず、時刻 $t-1$ における歩行者位置の推定結果である事後分布から、システムモデルである歩行者挙動モデル $p(\mathbf{x}_t|\mathbf{x}_{t-1})$ によって時刻 t における歩行者位置の分布を予測する($p(\mathbf{x}_t|\mathbf{z}_{t-1})$)。ついで、時刻 t における歩行者位置の観測データを取得する。取得データに基づいて尤度に相当する観測モデルを計算し、時刻 t における事後分布 $p(\mathbf{x}_t|\mathbf{z}_t)$ を推定する。

次に、この設定を拡張して、システムモデルのモデルパラメータが未知の場合を考える³⁾。この方法を自己組織化モデリングと呼ぶ。まず、状態ベクトルの定義として位置 $\mathbf{x}_t$ とシステムモデルのパラメータ $\boldsymbol{\theta}_t$ との両方を定義する。つまり、新しい状態ベクトルを

$$\tilde{\mathbf{x}}_t = \begin{pmatrix} \mathbf{x}_t \\ \boldsymbol{\theta}_t \end{pmatrix} \quad (5)$$

と定義する。このとき、システムモデルと観測モデルは、

$$p(\tilde{\mathbf{x}}_t | \tilde{\mathbf{x}}_{t-1}) = \begin{pmatrix} p(\mathbf{x}_t | \mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1}) \\ p(\boldsymbol{\theta}_t | \mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1}) \end{pmatrix} = \begin{pmatrix} p(\mathbf{x}_t | \mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1}) \\ p(\boldsymbol{\theta}_t | \boldsymbol{\theta}_{t-1}) \end{pmatrix} \quad (6)$$

$$p(\mathbf{z}_t | \tilde{\mathbf{x}}_t) = p(\mathbf{z}_t | \mathbf{x}_t, \boldsymbol{\theta}_t) = p(\mathbf{z}_t | \mathbf{x}_t) \quad (7)$$

にそれぞれ従うと想定する。つまり、本研究では、式(6)のようにシステムモデルが位置とパラメータとで独立に適用できると想定する。また、式(7)のように観測した歩行者位置は状態ベクトルのうち位置のみに従属して生起すると想定する。さて、このとき事後分布は式(1)と全く同様の手続きによって推定できる。すなわち、

$$\begin{aligned} p(\tilde{\mathbf{x}}_t | \mathbf{z}_{1:t}) &\propto p(\mathbf{z}_t | \tilde{\mathbf{x}}_t) p(\tilde{\mathbf{x}}_t | \mathbf{z}_{1:t-1}) \\ &= p(\mathbf{z}_t | \tilde{\mathbf{x}}_t) \int p(\tilde{\mathbf{x}}_t | \tilde{\mathbf{x}}_{t-1}) p(\tilde{\mathbf{x}}_{t-1} | \mathbf{z}_{1:t-1}) d\tilde{\mathbf{x}}_{t-1} \\ &= p(\mathbf{z}_t | \mathbf{x}_t) \left(\int p(\mathbf{x}_t | \mathbf{x}_{t-1}, \boldsymbol{\theta}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{z}_{1:t-1}) d\mathbf{x}_{t-1} \right. \\ &\quad \left. \int p(\boldsymbol{\theta}_t | \boldsymbol{\theta}_{t-1}) p(\boldsymbol{\theta}_{t-1} | \mathbf{z}_{1:t-1}) d\boldsymbol{\theta}_{t-1} \right) \end{aligned} \quad (8)$$

である。右辺のシステムモデルのうち $p(\mathbf{x}_t|\mathbf{x}_{t-1},\boldsymbol{\theta}_{t-1})$ は $\boldsymbol{\theta}_{t-1}$ をパラメータとする歩行者挙動モデルである。また、 $p(\boldsymbol{\theta}_t|\boldsymbol{\theta}_{t-1})$ は $\boldsymbol{\theta}$ のシステムモデルであり、一般にランダムウォークを仮定する³⁾。この事後分布を $\mathbf{x}_t$ で周辺化することにより、 $\boldsymbol{\theta}_t$ の事後分布が推定できる。

$$p(\boldsymbol{\theta}_t | \mathbf{z}_{1:t}) = \int p(\tilde{\mathbf{x}}_t | \mathbf{z}_{1:t}) d\mathbf{x}_t \quad (9)$$

式(9)のパラメータ事後分布もベイズの法則に基づいて計算されており、各時刻においてパラメータが逐次最適化されていることとなる。この式(9)を時系列に並べたものが、本研究で行うパラメータ推定の結果である。また、必要であれば2.(1)で述べた代表値を用いたり、特定のパラメータについて周辺化したりする。

以上より、一般状態空間モデルを用いて歩行者挙動モデルのパラメータを推定すれば、以下のことを実現できる。まず、逐次ベイズ推定によって、パラメータが各時刻で逐次的に推定されていく。そのため、逐次的に取得されるデータに対して逐次的にパラメータ推定を行える。その結果としてパラメータの時間変化を追うことが可能となる。さらに、計測誤差およびシステムモデルによる予測誤差を観測モデルとしてモデル化することができる。近年進展している離散選択型の挙動モデルは、連続的な歩行空間を離散的な複数の点で代表させるものである。従って、原理的に予測誤差が発生するモデルといえる。一般状態空間モデルは、このようなモデルに対しても有効なパラメータ推定手法であると考えられる。

なお、推定には式(8)に含まれる積分を計算する必要がある。この式は一般に解析的に求めることはできない。そこで、パーティクルフィルタ^{5,6)}により数値積分を行う。

3. 一般状態空間モデルの構成要素の設定

本章では、本研究における一般状態空間モデルの構成要素の設定を説明する。

(1) 使用データ

2010年11月29日の朝ラッシュ時に、鉄道駅の改札付近で動画を撮影した(図-2)。この動画を23[s]ごとに静止画として切り出したうえで、床面が平面であると仮定して導出したカメラパラメータを利用して座標変換を行い、各時刻における平面上の歩行者位置をマニュアルで取得した。よって、以下では、一般状態空間モデルにおける1タイムステップは23[s]である。推定には130タイムステップ(およそ90秒間)のデータを用いた。この間に、

図-2 撮影画像の例

図-3 離散選択モデルの選択肢形状

対象とする10[m]×20[m]程度の領域内に、最大で30人程度の歩行者が同時に存在している。

(2) 推定する歩行者挙動モデル

前章の通り、システムモデルとして推定対象の歩行者挙動モデルを設定する。本研究では、近年進展している、離散選択型の挙動モデルを推定することとする。歩行者は各タイムステップで速度3種類・角度5種類により異なる15個の選択肢の中から移動先を選択する(図-3)。データセットにおいては、完全に静止する歩行者は存在せず、すべての時刻・歩行者についてこの選択肢が定義できた。多項ロジットモデルを用い、既往の研究⁷⁹⁾を参考に、選択肢*i*についての効用関数を以下のように設定した。

$$\begin{aligned}
 V_i = & \beta_{dist} dist_i \quad (a) \\
 & + \beta_{dir} dir_i \quad (b) \\
 & + I_{acc} \left\{ -\beta_{acc} + (v_{max} - v)^{\lambda_{acc}} \right\} \quad (c) \\
 & + I_{dec} \left\{ -\beta_{dec} + v^{\lambda_{dec}} \right\} \\
 & + \beta_{col} D_i \quad (d)
 \end{aligned} \quad (10)$$

ここで、 β と λ が推定すべきパラメータであり、それぞれの項の意味するところは以下の通りである。

(a) 目的地に向かう行動

歩行者は目的地に近い選択肢を好むことを表している。 $dist_i$ は選択肢*i*と目的地との距離[m]であり、 β_{dist} には負が期待される。目的地は使用データにおける各歩行者の到達地点の座標を用いている。

(b) 進行方向を維持する行動

歩行者にはむやみに進行方向を変更せず直進する傾向があることを表している。 dir_i は現在の進行方向と選択肢*i*への方向との角度[°]であり、 β_{dir} には負が期待される。

(c) 歩行速度を希望速度に近づける行動

歩行者は希望速度に近い速度で歩こうとする。現在速度が小さいときには加速選択肢が、大きいときには減速選択肢が好まれることを表している。

I_{acc} は加速選択肢(1-5)のとき、 I_{dec} は減速選択肢(11-15)のとき1となるダミー変数である。 v は対象歩行者の現在の速さ[m/step(=2/3[s])]である。 v_{max} は歩

表-1 離散選択モデルの最尤推定結果

サンプル数	2780	
修正済み尤度比	0.38	
変数名	推定値	t値
β_{dist} 目的地との距離	-9.38***	-36.70
β_{dir} 進行方向変更の角度	-0.46***	-28.05
β_{acc} 加速選択肢の定数項	7.81***	49.41
λ_{acc} 低速時の加速	2.68***	45.56
β_{dec} 減速選択肢の定数項	-0.33***	-4.33
λ_{dec} 高速時の減速	2.94***	13.56
β_{col} 周辺歩行者の回避	-0.52***	-8.01

t値は $\beta=0$ および $\lambda=1$ に対して算出、***: 1%有意

行者の最大速さを表す定数であり、データセットにおける最大値の3.87[m/s]としている。このように、各歩行者の希望速度を明示的に扱うのではなく、加減速の不効用を β_{acc} および β_{dec} で定数項として表現し、現在速度に依存した加減速の効用を λ_{acc} および λ_{dec} で表現している。 β_{acc} 、 β_{dec} 、 λ_{acc} および λ_{dec} には正が期待される。

(d) 周辺歩行者への接近を避ける行動

歩行者は混雑状況下では周辺歩行者への接近を避ける傾向にある。 D_i は周辺歩行者が直進する場合に時刻*t*+1で選択肢*i*に最も接近する周辺歩行者と選択肢*i*との距離であり、 β_{col} には負が期待される。

なお、図-3の選択肢間には誤差相関が存在すると考えられるため、本来はクロスネスティッドロジットモデルなどの適用がより適切であるが、本研究はパラメータ推定方法の検討を主目的とするため、簡単のため式(10)を効用関数とする多項ロジットモデルを採用している。

このモデルについて、適用時の参考とするために2780個のサンプルを用いて最尤推定を行った(表-1)。尤度比、符号条件、t値ともにおおむね良好な推定結果となっている。ただし、 β_{dec} が想定と異なり負の値となっている。これは、推定に用いたデータセットが改札に到達する行動を対象としており、すべての歩行者が改札に向かうにつれて減速する傾向があるためと考えられる。

(3) 一般状態空間モデルの構成要素の設定

次に、歩行者挙動モデル以外の一般状態空間モデルの構成要素を設定する。

a) 状態ベクトル・観測ベクトル

状態ベクトルには、時刻*t*における各人物の位置と、上記(2)で設定したパラメータ7個を並べたものを定義する。また、観測ベクトルには、上記(1)で手動で得た各人物の人物位置を与える。すなわち、

$$\tilde{\mathbf{x}}_t \equiv \begin{pmatrix} \mathbf{x}_t \\ \mathbf{0}_t \end{pmatrix} = \begin{pmatrix} (x_1, y_1, \dots, x_n, y_n)^T \\ (\beta_{dist}, \beta_{dir}, \beta_{acc}, \lambda_{acc}, \beta_{dec}, \lambda_{dec}, \beta_{col})^T \end{pmatrix} \quad (11)$$

$$\mathbf{z}_i = (\dot{x}_i, \dot{y}_i, \dots, \dot{x}_n, \dot{y}_n)^T \quad (12)$$

ただし、時刻 i において n 人の人物が存在し、手動で取得した位置を $\dot{x}, \dot{y}$ と表記している。

b) 観測モデル

観測モデルは、状態ベクトルと観測ベクトルの位置座標の近さによりモデル化する。具体的には、

$$p(\mathbf{z}_i | \tilde{\mathbf{x}}_i) = p(\mathbf{z}_i | \mathbf{x}_i) \propto \exp \left[-\frac{1}{2\sigma_{obs}^2} \left(\frac{\sum_{i=1}^n |d_i|}{n} \right)^2 \right] \quad (13)$$

$$d_i = \sqrt{(\dot{x}_i - x_i)^2 + (\dot{y}_i - y_i)^2} \quad (14)$$

とする。すなわち d_i は歩行者 i についての予測位置と観測された位置との距離[m]である。ただし、 n は時刻 i において観測された歩行者数である。従って、式(13)は各時刻における歩行者1人あたりの予測誤差と計測誤差との和が、平均0・分散 σ_{obs}^2 の正規分布に従うと仮定したモデルである。計測誤差の大きさを見積もることができる場合、分散の大きさを決定する際の参考とすることができる。たとえば、本研究で用いる画像(図-2)では、手動でのプロット位置が1ピクセル異なると、平面上でおよそ3[cm]異なる位置に対応することがわかっている。

c) システムモデル

システムモデルのうち、歩行者挙動モデルに相当する部分 $p(\mathbf{x}_i | \mathbf{x}_{i-1}, \mathbf{0}_{i-1})$ は(2)で述べたとおりである。パラメータのシステムモデル $p(\mathbf{0}_i | \mathbf{0}_{i-1})$ に相当する部分は前述の通りランダムウォークとする。ランダムウォークの分散 σ_{ys}^2 はパラメータが1タイムステップあたりに変化しうる大きさを規定する。データに対して高い感度で推定したい場合には大きめの値を、長期的に安定したパラメータ値を推定したい場合には小さめの値を設定することとなる。

d) 初期分布

初期分布のうち、位置に関する分布 $p(\mathbf{x}_0)$ は、一般的な設定³⁾と同様に正規分布を仮定する。具体的には、平均を手動で取得した $\dot{x}_0, \dot{y}_0$ 、分散をb)で説明した観測モデルと同じ値とする。パラメータの初期分布 $p(\mathbf{0})$ はベイズ推定における一般的な考え方に基いて設定する。すなわち、パラメータの値に関する情報が全くない場合には一様分布や分散の大きな正規分布を、別途推定した結果がある場合にはその分布を設定する⁴⁾。

4. 推定結果と考察

本章では、以上の設定のもとで実データを用いて歩行者挙動モデルのパラメータを逐次推定し、1.で述べた(a)から(d)までの4つの観点について順に結果を示し考察を行う。なお、パーティクルフィルタ計算時のパーティク

ル数は 2^{15} (=32768)個とした。 2^{10} (=1024)個から 2^{16} (=65536)個まで試行した結果を比較し、精度に大きな差を与えない程度に十分多い個数と判断したものである。

(1) パラメータ初期分布の推定結果への影響

パラメータ初期分布 $p(\mathbf{0})$ に以下の3種類を設定して推定を行う。なお、 $\sigma_{ys}^2 = \sigma_{obs}^2 = 0.01$ とする。

(a) 3.(2)で求めた最尤推定値を用いる場合

最尤推定において求まる平均・分散の推定量を持つ正規分布を設定する。

(b) 一様分布を用いる場合(1)

3.(2)で述べた符号条件に基づいて、正が期待されるパラメータには $\text{unif}(0,10)$ を、負が期待されるパラメータには $\text{unif}(-10,0)$ を与える。

(c) 一様分布を用いる場合(2)

すべてのパラメータに $\text{unif}(-10,10)$ を与える。

3種類の推定結果を7個のパラメータそれぞれについて周辺化し、事後平均を比較した(図-4、表-2)。赤線が(a)、青線が(b)、黄緑線が(c)を示している。留意点として、逐次最適化においては、初期分布が異なれば一般に事後平均は同じ値に収束しない。そのため、ここではパラメータの符号や時系列変化の様子など定性的な解釈を行う。

まず、いずれのパラメータにおいても、初期分布の設定によらず、時間経過とともに事後平均の時系列変化が穏やかになっていく。このことから、一般状態空間モデルを用いたパラメータ逐次推定においては、あらかじめパラメータ値に関する情報を有していなくても、時間経過とともにデータが増えていけば安定的に推定が可能であるといえる。次に、個々のパラメータについて検討すると、 $\beta_{bkr} \cdot \beta_{bkr} \cdot \beta_{acc} \cdot \beta_{cal}$ はいずれの設定においても同符号となっている。そのため、これらの変数が歩行者挙動に対して与える影響は、おおむね前章での想定通りであると考えられる。一方で、 $\lambda_{acc} \cdot \lambda_{dec}$ は設定により大きく異なる値となっている。一般に指数パラメータの推定は不安定となりやすいため、今後より詳細な検討が必要である。また、最尤推定において想定に反する符号となった β_{dec} は、ここでは設定によって異なる符号となった。この意味解釈は今後の課題である。近年、事前分布が推定結果に与える影響を定量的に把握する手法が提案されており⁹⁾、このような手法による検証が考えられる。

ここで、以降の考察に先立ち、初期分布(a)により推定されたモデルの基本性能を、データセットに対する再現性により確認した(図-5)。選択肢ごとに、データセットにおける選択数を青色、3.(2)で求めた最尤推定値による選択確率の和を橙色、逐次ベイズ推定による事後平均値を用いた選択確率の和を赤色で示した。橙色と赤色の形状がおおむね一致していることから、パラメータ推定手法としての一般状態空間モデルを用いた逐次ベイズ推定

このページのグラフは、別途表記が無い限り横軸は時刻[s]、縦軸はパラメータ値である。

赤: 初期分布(a), 青: 初期分布(b), 黄緑: 初期分布(c)による事後平均

図4 初期分布の違いによる事後分布の推定結果

表-2 $t=90[s]$ における逐次ベイズ推定結果 (事後平均)

初期分布	(a)	(b)	(c)
β_{dist}	-9.99	-8.14	-10.52
β_{dir}	-2.40	-6.36	-5.50
β_{acc}	9.11	9.92	5.95
λ_{acc}	3.43	2.47	-4.28
β_{dec}	-0.93	2.92	0.52
λ_{dec}	3.16	7.34	0.15
β_{col}	-2.37	-1.72	-5.06

赤: 事後平均, 青: 25, 50および75パーセンタイル値

青: 実際の選択数, 橙: 最尤推定値 / 赤: 事後平均値による選択確率

図5 モデルによる選択肢予測結果のヒストグラム

図6 パラメータ値の変化と実際の歩行空間の状況の比較

赤・青: $\sigma_{ys}^2=0.01$, 茶・緑: $\sigma_{ys}^2=0.1$

図7 パラメータの時系列変化の制御

赤: $\sigma_{obs}^2=0.01$, 青: $\sigma_{obs}^2=0.09$

図8 計測精度とパラメータ推定結果の関係

は、少なくとも最尤推定と同程度の性能を有すると考えて差し支えないだろう。

(2) パラメータの時系列変化と実現象との関係

パラメータの時系列変化と実際の歩行空間で起きている現象との関係について検討する。初期分布に最尤推定値を用い、 $\sigma_{ys}^2=\sigma_{obs}^2=0.01$ とした設定について、取得した

動画と比較した。図-6は、パラメータ β_{dir} と β_{dec} について事後分布の時刻 $t=40[s]$ 付近を拡大し事後平均と25, 50および75パーセンタイル値を示したものと、取得動画とを示している。乗客が集中し改札に待ち行列ができてい状況で、 β_{dir} が負の小さい値となり β_{dec} は正から負の値に変化している。すなわち、待ち行列が一度形成されると、歩行者は列に並び低速で直進する行動をとること

から、進行方向変化の不効用および減速の効用が増加する推定結果となったと解釈できる。このことから、歩行空間の実際の状況が、推定されるパラメータの時系列変化に逐次的に反映されているものと考えられる。一般状態空間モデルを用いたパラメータ推定の利点が表れている一例といえるだろう。

(3) パラメータの時系列変化の制御

3.(3)c)で説明したパラメータのシステムモデル $p(\theta|0:t)$ のランダムウォークについて、分散 σ_{θ}^2 の大きさを0.01と0.1の2種類試行する。なお、初期分布は最尤推定値、 $\sigma_{\theta}^2=0.01$ とする。推定結果をパラメータ β_{acc} の時刻 $t=50[s]$ から $90[s]$ 付近を例に示す(図-7)。 $\sigma_{\theta}^2=0.01$ のときの事後平均を赤線、25および75パーセンタイル値を青線で示している。また、 $\sigma_{\theta}^2=0.1$ のときの事後平均を茶線で、25および75パーセンタイル値を緑線で示している。事後平均は、平均的には9付近の値を取っているが、大きい σ_{θ}^2 を設定するとパラメータの時系列変化が激しくなることがわかる。また、パーセンタイル値の時系列変化をみると、大きい σ_{θ}^2 においては事後分布の裾が広くなることもわかる。このように、分散の大きさを変更することにより、データに対してパラメータが適応する感度を調節することができることが確認できる。

(4) データ計測精度と推定結果との関係

データ計測精度が推定結果に与える影響を検討するために、3.(3)b)で説明した観測モデルの分散について複数の設定で推定を行う。具体的には、観測モデルの分散 σ_{obs}^2 を0.01と0.09の2種類試行した。これは、仮に観測モデルが正規分布に従うとすれば、その標準偏差が10[cm]および30[cm]に相当する。初期分布は最尤推定値、 $\sigma_{\theta}^2=0.01$ とする。推定結果のうち、両者で事後平均の値の差異が大きかったパラメータ β_{dec} と β_{col} を示す(図-8)。ここで、挙動モデルの効用関数において減速選択肢に相対的に高い効用を与えうるのは、この2つのパラメータのみであることに注意すると、パラメータ値から挙動モデルにおける減速行動の表現力を推察することができる。 $\sigma_{obs}^2=0.01$ のときは β_{dec} が負であり、減速行動に無条件で正の効用が発生する。 β_{col} も負であることから、歩行者は現在速度によらず減速しようとし、前方に他者がいる場合にはより減速しようとすることを示している。一方で、 $\sigma_{obs}^2=0.09$ のときは β_{dec} が正であり、 β_{col} は $\sigma_{obs}^2=0.01$ のときよりも大きい値であることから、相対的に挙動モデルにおける減速行動が表現されにくくなっているといえる。つまり、この挙動モデルにおいては、データ取得時の計測精度が減速行動の表現力に影響することが示唆される。

実際にも、図-3に示した選択肢形状において、選択肢相互の距離は現在の歩行速度が小さければ10[cm]程度の

間隔となる。そのため、 $\sigma_{obs}^2=0.09$ 程度まで計測精度が低下すると、複数の選択肢を実質的に区別することができなくなる。すなわち、減速行動を表すようにみえる計測データも、減速行動を精度良く計測したもの・速度維持行動を劣る精度で計測したもののどちらであるか区別できなくなる。この状況で推定を行うときに減速行動の表現力が低下するという傾向は妥当であろう。

5. おわりに

本研究では、一般状態空間モデルを利用した歩行者挙動モデルのパラメータ推定について検討した。この推定手法が逐次ベイズ推定であることを説明し、最尤推定に代表される従来手法では考慮が困難であったモデルパラメータの時系列変化やデータ計測誤差の考慮が可能であるという利点を明らかにした。そのうえで、駅構内における歩行者挙動の実データを用いて実際にモデルパラメータの推定を行い、これらの利点を実証的に示した。また、推定時に分析者が行う設定について、初期分布、パラメータのランダムウォーク、観測モデルの分散それぞれの設定が推定結果に与える影響について議論した。さらに、推定結果と実際の歩行空間の状況との照合を行った。いずれの議論においても推定結果は妥当な傾向を示しており、一般状態空間モデルを利用したパラメータ逐次ベイズ推定の有効性を明らかにした。

ただし、今回の適用においては、推定時の設定方法によって事後分布に差が生じる理由について、必ずしも詳細に把握できていないといえない。本手法を多くのパラメータ推定に適用することにより、初期分布をはじめとする設定についてより適切な方法を探っていくことが今後の課題である。また、現時点では、パラメータ推定自体の精度評価は定性的な議論にとどまっている。これに対し、一般状態空間モデルにおけるモデル全体の評価方法として予測尤度と呼ばれる指標がある。この指標を用いてパラメータの推定精度評価を定量的に行っていくことも必要である。さらに、今後の展望として、逐次推定の結果を利用したリアルタイムでの流動制御があげられる。このためには、事後平均や事後分布全体の時系列変化について解釈する方法を確立していくことが望まれる。

謝辞：本研究は科学研究費(特別研究員奨励費)の助成により行われた。推定に用いたデータセットは若生凌氏(東京大学大学院修士課程(当時))の協力により作成された。ここに記して感謝の意を表する。

参考文献

- 1) Duives, D. C., Daamen, W. and Hoogendoorn, S. P. : State

- of-the-art crowd motion simulation models, *Transportation Research Part C: Emerging Technologies*, Vol. 37, pp. 193-209, 2013.
- 2) 田代祐志, 川本一彦: 複数人物追跡のためのセルオートマトン型歩行者行動モデルのパラメータ推定に関する基礎検討, 情報処理学会研究報告, Vol. 2011-CVIM-177, No. 6, pp. 1-8, 2011.
 - 3) 樋口知之 編著: データ同化入門—次世代のシミュレーション技術, 朝倉書店, 2011.
 - 4) 安道知寛: ベイズ統計モデリング, 朝倉書店, 2010.
 - 5) Gordon, N., Salmond, D. and Smith, A.: Novel approach to nonlinear/non-Gaussian Bayesian state estimation, radar and signal processing, *IEEE Proceedings F*, Vol. 140, No. 2, pp. 107-113, 1993.
 - 6) Kitagawa, G.: Monte Carlo filter and smoother for non-Gaussian nonlinear state space models, *Journal of Computational and Graphical Statistics*, Vol. 5, No. 1, pp. 1-25, 1996.
 - 7) Robin, T., Antonini, G., Bierlaire, M. and Cruz, J.: Specification, estimation and validation of a pedestrian walking behavior model, *Transportation Research Part B*, Vol. 43, pp. 36-56, 2009.
 - 8) 柳沼秀樹, 松山宣弘, 福田大輔: 障害物の視認性を考慮した離散選択型歩行者挙動モデルの構築, 第 30 回交通工学研究発表会論文集, pp.337-340, 2010.
 - 9) 渡辺澄夫: ベイズ統計の理論と方法, コロナ社, 2012.

(2015.2.27 受付)

APPLICATION OF GENERAL STATE SPACE MODEL TO PARAMETER ESTIMATION OF PEDESTRIAN BEHAVIOR MODEL

Wataru NAKANISHI, Mami TAKAHASHI and Takashi FUSE

This paper shows a new approach to estimate parameters of pedestrian behavior model. The approach applies general state space model. In this modelling, parameter estimation is formulated as a sequential Bayesian filtering. Thus we can estimate time varying parameters which are adaptive to sequentially acquired data. Also we can deal with observation errors. Firstly we include parameters into state vectors of a general state space model and formulate an estimation equation. Secondly we define components of that model: state vector, observation vector, system model, observation model and initial distributions. Then we apply this settings to data acquired at a railway station and estimate time varying parameters. We compared estimation results with estimation settings; we discuss effects of initial distributions, variance of random walk parameters and observation accuracies. In addition, we compared estimated parameters with real situations and confirm that parameters are adaptively changed to congestions.