

複数モデルの混合による 歩行者の行動分析に向けた検討

中西 航¹・布施 孝志²

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

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

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

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

歩行空間の設計や評価において歩行者の行動原理を知ることは重要であり、歩行者の意思決定を明示的に扱うミクロな歩行者挙動モデルは有用と考えられる。しかし、従来の単一の挙動モデルでは動線の再現性が確保されないという問題がある。そこで、本研究では、歩行者行動分析への展開を念頭に、複数の挙動モデルを確率的に混合することによりモデルの表現力を高める方法を検討する。はじめに混合モデルの構築方法について整理し、特に時系列を考慮した方法として動線データに対して定式化を行う。推定方法を説明したうえで、簡単な設定において実データに適用し、今後の展望を示す。

Key Words : *pedestrian behavior analysis, mixture model, model switching, time series analysis, sequential Bayesian estimation*

1. はじめに

ミクロスケールでの歩行者挙動を表現するモデルとして、近年になり歩行者個人々の意思決定を明示的に扱うモデルが構築されてきた。例として2006年に発表されて以来¹⁾効用最大化理論に基づく離散選択モデルが注目されている。このようなモデルは、歩行者の行動原理を直接変数としてモデル化しているため、モデル推定結果の意味解釈が容易である。ただし、後述するように、モデル推定時の仮定が現実的でない場合があるため、動線の再現性に問題を有していることが多い。ゆえに、推定結果の意味解釈の信頼性にも疑問が残るという現状がある。

先に述べたモデル推定時の仮定について、推定に用いるデータの性質をもとに説明する。一般に、歩行者挙動モデルの推定においては、動線を1秒程度のタイムスライスで点に離散化し、各時刻で各歩行者の位置・速度・加速度などを列挙したものをデータセットとして用いる。そして、データセットに含まれるそれぞれのデータが、背後にある単一の生成モデル、すなわち歩行者の意思決定システムから発生していると仮定する。しかしながら、この仮定：各歩行者が毎時刻で独立に意思決定を行っているという仮定は、タイムスライスが1秒程度の場合に、生成モデルが複雑になるにつれて現実的ではなくなっていくと考えられる。より具体的には、離散選択型のモデ

ルにおいて、各歩行者が1秒に1度のような高頻度で意思決定を行っており、その際に複雑な効用関数の全容を正しく認識できるという仮定であるが、この妥当性の検討は行われていない。

しかし、歩行空間の設計や評価において歩行者の行動原理の理解が重要となる限り、意思決定を明示的にモデル化すること自体は重要であろう。そこで、本研究では、複数のモデルを確率的に混合するモデル：混合モデルを用いることにより、前述の仮定をより現実に近づけ、歩行者の行動分析に繋げていく方法を検討する。ここで考えていることは、

- ・意思決定を明示する生成モデルが複数存在する
 - ・生成モデルの混合モデルからデータが得られる
- ということであり、最終的な目的意識は、
- ・得られたデータのみから複数の生成モデルおよびその混合状態を推定する
 - ・推定結果により歩行者の行動分析を試みる
- という手法を確立していくことにある。

なお、歩行者挙動が混合モデルで表現可能であると考えられることは、広く用いられるセルオートマトンとの比較からも妥当である。すなわち、動線の再現性を確保しやすいセルオートマトンは、一つ一つの生成モデルを示すことなく混合モデル自体を直接推定しているモデルであると説明できる。

以下では、混合モデル構築の前提を述べ(2)、時系列モデルにおいて定式化と推定方法を整理し(3)、実際に推定を行い(4)、今後の展望を述べる(5)。

2. 歩行者挙動と混合モデル表現

(1) 離散選択型モデルにおける課題

意思決定を明示的に扱えるモデルの代表例が離散選択型モデルである。このモデルでは、各時刻で各歩行者に対し、次の移動先の候補を離散的な複数の点として与える。そして、各歩行者は、特定した効用関数に基づいて効用を最大化するように移動先を選択する。この際に、効用関数には、目的地方向への移動、現在速度の維持、進行方向の維持、周辺歩行者の回避、前方歩行者への追従などの要素が変数として組み込まれる。このモデルを推定する際の一般的な仮定として、

- ・各歩行者は毎時刻独立に効用関数に基づいて意思決定を行う
- ・各歩行者は各時刻で全選択肢とその効用を認識している

という2点がある。しかしながら、前述のとおり、これらの仮定の妥当性は検証されてこなかった。

これらの仮定が推定結果に与える影響の具体例を以下に述べる。多くの離散選択型モデルの推定結果では、歩行者の進行方向維持、すなわち直進行動が支配的な変数となっている。これは、データセット内に直進しているデータが多いことに起因する問題である。直進しているデータのすべてが単一のシステムによる意思決定の結果であると捉えたうえでモデル推定を行うと、直進性が強く反映されたモデルが構築されやすいことは自明である。しかし実際には、直進しているデータのすべてが複雑な効用関数に基づく意思決定の結果であるとは考えにくい。むしろ、意思決定を行わずに直進している、換言すると、無条件で直進する(直進選択肢しかない)という意思決定を行っているという捉え方が自然に思われる場合もある。

そこで、次節以降で、データセットを得たときに、各データを生成するモデルの個数、形式、混合率などを同時に推定する方法を検討する。

(2) 混合モデル構築の前提条件

いま考えている問題を整理すると、歩行者挙動のデータセット：時刻 t における移動ベクトル \mathbf{m} を得たときに、

- ・歩行者が従うモデルの個数 K
- ・各モデルが利用される割合(混合率) π_k
- ・各モデルの形式 p_k
- ・各モデルに含まれるパラメータ θ_k

のいくつか、またはすべてを推定することである。

本研究では、 K および p_k は事前に既知である、という想定のもとで以降の議論を行う。すなわち、分析者は、自身が有する想定に基づいて、歩行者が従うであろうモデル K 個と、それらのパラメトリックな形状とを外生的に与えることを考える。これに対し、 K および p_k も未知変数と考える方法は、よりデータマイニングに近い手法となり、データからモデルそのものを自動生成する場合に適していると考えられる。具体的な方法としては、 K そのものを未知とする場合には、 π_k の事前確率としてディクレ過程を導入することが可能である²³⁾。また、 p_k を未知としてモデル形状自体を生成する方法としては、遺伝的アルゴリズムの応用が考えられる⁴⁾。

(3) 時系列についての想定

次に、データセットの扱い方について、時系列の考慮という観点から説明する。

時系列を考慮しない方法では、データの時系列方向の関係性は考慮せず、すべてのデータを独立に同一のモデルから発生したサンプルである、と考える。従来の離散選択型の挙動モデル推定はこの考え方に相当する。混合モデルの単純な例としては、

$$f(\mathbf{m} | \boldsymbol{\pi}, \boldsymbol{\theta}) = \sum_{k=1}^K \pi_k p_k(\boldsymbol{\theta}_k), \quad \sum_{k=1}^K \pi_k = 1 \quad (1)$$

があげられる。このとき、 π_k および $\boldsymbol{\theta}_k$ を同時推定することが可能である。なお、混合モデルであることから、最尤推定ではなくベイズ推定が望ましいとされている⁹⁾。ただし、このモデル混合方法では、どのような条件下でどのモデルが選択されやすいのかを解釈できない。

次に、「モデル選択モデル」として $\boldsymbol{\pi}(\mathbf{w})$ を統合することを考えたものが以下である。

$$f(\mathbf{m} | \boldsymbol{\pi}, \boldsymbol{\theta}) = \sum_{k=1}^K \pi_k(\mathbf{w}) p_k(\boldsymbol{\theta}_k), \quad \sum_{k=1}^K \pi_k(\mathbf{w}) = 1 \quad (2)$$

ここで、 $\pi_k(\mathbf{w})$ は、特定の k のときに1、それ以外の時に0を返す離散的な「モデル決定」でも、全ての k について連続的な値を返す「モデル選択確率」でもかまわない。このモデルを具体的に記述・推定する方法としては、たとえばPlan-Actionモデルがある⁶⁾。ただし、歩行者挙動に適用する場合には、モデル選択モデル $\boldsymbol{\pi}(\mathbf{w})$ と、生成モデル $p_k(\boldsymbol{\theta}_k)$ とに同一の変数が含まれるように思われる場合が多く、変数選択およびパラメータ推定に困難を伴う。

そこで、本研究では、歩行行動分析を念頭に、推定結果の解釈可能性を重視することとし、以降では時系列を考慮する方法を検討する。すなわち、同一歩行者の移動先の選択は、その時刻よりも以前の移動先の選択方法に依存していることを考慮する方法である。この場合、どの時刻の、どの場所でのデータにおいて、どのようなモデル混合状況であったかということが事後的に理解できるため、行動分析の可能性が生まれてくる。

3. 混合モデルの定式化と推定方法

前章までの議論を踏まえ、本章では、具体的に時系列を考慮したモデルの混合方法を示し、その推定方法を述べる。なお、以降では、推定すべきパラメータが時間変動を伴うモデルを推定するため、計算量の観点から逐次ベイズ推定を前提とする。

(1) モデル混合率にガウス過程を導入する方法

式(1)および式(2)で示される混合モデルを時系列に拡張する方法を考える。式(2)の問題点：変数選択の困難さは時系列に拡張しても変化しないため、ここでは式(1)の時系列への拡張を考える。時間変動する変数としては、 π_k 、 θ_k および両者の3通りが考えられる。このうち θ_k を時間変動させる方法は、生成モデルの形状は同一だが、変数の影響力が異なる場合に相当するものであり、著者らの既報⁷⁾などに適用がある。これに対し、本研究で考えたいことは、大きく異なる生成モデルが複数存在することであるから、 π_k を時間変動する変数とみなす方法について考え、 θ_k はあらかじめ式(1)に基づいて推定するなど、事前に判明しているものと想定する。 π_k は総和が1という制約があることから、多項分布に従うと考えることができる。そこで、 π_k の背後にある多項分布の自然パラメータについてガウス過程を導入することにより、時系列を表現することが可能である。

具体的には、時刻 t における K 次元多項分布の平均パラメータが $\pi_{k,t}$ ($k=1,2,\dots,K$)であるとき、自然パラメータは

$$w_{k,t} = \log \left(\frac{\pi_{k,t}}{\pi_{K,t}} \right), \quad k = 1, 2, \dots, K-1 \quad (3)$$

であり、ガウス過程ではこれらをまとめて表記した \mathbf{w}_t が

$$\mathbf{w}_t | \mathbf{w}_{t-1} \sim N(\mathbf{w}_{t-1}, \sigma^2 I) \quad (4)$$

なる正規分布に従って遷移すると考える。このとき、便宜的に $w_{K,t} = \log(1) = 0$ とおくと、

$$\pi_{k,t} = \frac{\exp(w_{k,t})}{\sum_{k=1}^K \exp(w_{k,t})} \quad (5)$$

である。この平均パラメータに従って $k \sim \text{Mult}(\pi_{k,t})$ と選択されることから、以下の通り混合モデルが記述できる。

$$f(\mathbf{m} | \boldsymbol{\pi}, \boldsymbol{\theta}) = \int \pi_k p_k(\boldsymbol{\theta}_k) d\boldsymbol{\pi} \quad (6)$$

なお、 π_k の事前分布の与え方としては、式(1)の推定結果を用いることが考えられる。

(2) モデル選択行動に時間変化を導入する方法

前節の方法は、混合率の時間変化を想定しているのみであり、各歩行者のモデル選択そのものの時系列変化を

直接モデル化しているわけではない。そこで、より直接的にモデル選択をモデル化する方法として、モデル変更確率を表す遷移行列 \mathbf{C} を導入することを考える。経済学の分野でレジームスイッチングモデルとよばれ、広く用いられている方法である⁸⁾。たとえば、1次のマルコフ性に従うという前提のもとで、

$$\boldsymbol{\pi}_t = \mathbf{C}\boldsymbol{\pi}_{t-1} \quad (7)$$

と記述する。ただし、 $\boldsymbol{\pi}_t$ は k 行のベクトル、 \mathbf{C} は $k \times k$ の正方行列で列和が1である。このとき、 \mathbf{C} の i 行 j 列の要素は、時刻が1進むときにモデルが i から j に変化する確率を表している。この場合も、混合モデルは

$$f(\mathbf{m} | \boldsymbol{\pi}, \boldsymbol{\theta}) = \int \pi_k p_k(\boldsymbol{\theta}_k) d\boldsymbol{\pi} \quad (8)$$

である。 \mathbf{C} 自身を推定することや、 \mathbf{C} 自身も時間依存する行列と考えることは可能だが、計算上の困難がある。本研究では、事前に一定の値を持つ行列を与えるものとする。従って、分析者が事前にモデル変更に対する知識や想定を有している場合に適した手法と考えられる。なお、 \mathbf{C} が定常分布を持つ場合、非逐次推定の意味が理解しにくいいため、基本的には逐次推定に適した手法となる。

(3) 別の基準によりモデル選択をモデル化する方法

前節の方法を現実的に解こうとすると、行列 \mathbf{C} としてモデル変更確率を外生的に与えることになるが、与えた確率の妥当性が判断しにくいという問題がある。また、より一般に、モデル変更プロセス自体をモデル内部に記述すると計算量の増加が避けられない。そこで、モデル選択の基準を別途用意する方法も考える。具体的には、逐次ベイズ推定における予測尤度を基準とし、この尤度が別途定めた閾値を下回った場合にモデルを変更する方法を考える。これは、予測尤度によるモデルスイッチングと呼ばれている⁴⁾。予測尤度については続く節の式(10)で説明する。この方法では、モデルの混合方法を陽に記述することはできないため、プロセスを以下に示す。

1. モデル k をランダムに選択する
2. モデル k により逐次ベイズ推定を行う
3. 推定結果の予測尤度を閾値と比較する
4. 予測尤度が閾値を上回っていればそのまま2に戻る
下回っていればモデル k をランダムに選択し、 $k \leftarrow k'$ として2に戻る

なお、3.の比較をどの程度の時間幅で行うかや、4.のモデル変更の具体的なプロセスの設計は多様な方法が考えられる。尤度による判断は、元来は異常検知手法に近い方法である⁹⁾ため、モデル変更は低頻度に行われたいという想定の際に適していると考えられる。また、この場合も、外生的に与える閾値の妥当性の判断は容易ではない。

(4) 逐次ベイズ推定の方法

ベイズ推定とは、推定したいパラメータの事後分布、あるいは事後分布に基づくデータ分布を求めることであり、事後分布がパラメータの事前分布と尤度関数との積に比例することを利用してこれらを求めていく。ベイズ推定のひとつである逐次ベイズ推定とは、データを取得するたびに尤度関数を計算し、事前分布を事後分布に更新する方法である。この際に、計算された事後分布を新たな事前分布とみなし、次のデータの取得を行う。

本研究で考えている逐次ベイズ推定は一般状態空間モデルの枠組みにおいて実現可能である¹⁰⁾。具体的には、直接の観測が不可能な変数：状態ベクトル \mathbf{x}_t として、歩行者に関する変数(位置・速度)および時間変動するパラメータを設定する。また、直接観測する変数：観測ベクトル \mathbf{y}_t としてデータにおける歩行者位置を設定する。このとき、状態ベクトルの時間遷移を表す分布：システムモデル $p(\mathbf{x}_t|\mathbf{x}_{t-1})$ は、パラメータは上述の想定に基づいて遷移し、位置はその時刻でのパラメータ分布に基づいて計算されるモデルとなる。また、状態ベクトルから観測ベクトルを得る条件付き分布：観測モデル $p(\mathbf{y}_t|\mathbf{x}_t)$ が尤度関数に相当するものであり、たとえばデータの歩行者位置と状態ベクトルにおける予測位置との差分に基づく正規分布を仮定する。このとき、状態ベクトルの事後分布を求める式は、ベイズの法則により

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{y}_{1:t}) &\propto p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) \\ &= p(\mathbf{y}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) d\mathbf{x}_{t-1} \end{aligned} \quad (9)$$

となる。なお、 $\mathbf{y}_{1:t} = \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_t\}$ であり、時刻 t までのデータを用いて時刻 t における事後分布を得ることを示す。また、状態ベクトルのうちパラメータ部分についての事後分布を得たい場合は、他の要素で周辺化すれば良い。

前節で述べた予測尤度とは、式(9)の右辺の積分である。すなわち、

$$\int p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) d\mathbf{x}_t \quad (10)$$

である。この値が大きいほど、現在の事後分布において現在までのデータが得られる尤度が大きいことを示しており、モデルの良さを示す指標となる。

式(9)に含まれる積分は、解析的に解ける場合はそのまま計算すれば良いが、非線形である場合にはアンサンブルカルマンフィルタやパーティクルフィルタ¹¹⁾¹²⁾などの近似方法を用いる。また、パーティクルフィルタの近似精度を上げる方法として、解析的に計算できる部分とそれ以外に分離するラオ・ブラックウェル化¹³⁾¹⁴⁾があり、本研究の設定にも適用可能性がある。ただし、推定結果を比較する都合上、次章ではパーティクルフィルタ(パーティクル数32768)で近似した結果を示す。

4. 適用

(1) データとモデル候補の設定

前章で述べた3種類の方法について、簡単な設定のもとで実際の動線データに対して適用する。適用対象として、横断歩道を撮影した30分程度の映像(図-1)から取得した動線データのうち、10人分を用いる。

モデル設定は $K=2$ とし、離散選択型のモデル($k=1$)と等速直線運動を行うモデル($k=2$)との2種類を用意する。前述の通り、直進データが多い状況に対して、複雑な選択の結果としての直進と無条件での直進との混合モデルとして表現することを意図している。また、簡単のため、離散選択モデルのパラメータ θ を同時推定することはせず、事前に推定されているものを用いることとする。

利用する離散選択モデルは横断歩道データでの検証実績があることからRobin *et al.*によるモデル¹⁵⁾とする。このモデルは速度・角度に応じた33個の選択肢を設け、効用関数に進行方向維持、目的地への接近、加減速の負担、前方歩行者への追従および回避を組み込み、速度と角度それぞれに誤差相関を考慮したクロスネスティッドロジットモデルとなっている。なお、変数に含まれる目的地の位置は、横断歩道を渡り終えてから5秒後の各歩行者の位置としている。

逐次ベイズ推定を行うための設定は以下の通りである。状態ベクトルには、推定される(観測データではない)歩行者位置 \mathbf{x}_t と各設定において時間変化するパラメータ(\mathbf{w} ないし $\boldsymbol{\pi}$)とを設定する。また、観測ベクトルには取得データを時系列に並べたものを設定する。すなわち、各時刻における歩行者の位置 \hat{x}_t, \hat{y}_t とする。システムモデルは、位置 $\mathbf{x}_t, \mathbf{y}_t$ については選択されたモデルにおける移動ベクトルを与え、パラメータについては各設定にそのまま従うものとする。尤度関数、すなわち観測モデル $p(\mathbf{y}_t|\mathbf{x}_t)$ は、状態ベクトルと観測ベクトルとの位置座標の近さによりモデル化する。具体的には、

$$p(\mathbf{y}_t | \mathbf{x}_t) \propto \exp \left[-\frac{d_t^2}{2\sigma_{obs}^2} \right] \quad (11)$$

$$d_t = \sqrt{(\hat{x}_t - x_t)^2 + (\hat{y}_t - y_t)^2} \quad (12)$$



図-1 撮影画像の例と座標系

とする。すなわち d_t は時刻 t における歩行者の予測位置と観測された位置との距離[m]である。また、適用を通して $\sigma_{obs}=0.3$ とする。

(2) 推定結果

以下で、各設定において必要な設定を述べ、推定結果を説明する。どの設定・どの歩行者についても、歩行者位置の推定精度はおおむね30[cm]程度に収まっており、従来手法と比較しても一定の性能を有することを確認した。

以降では、1人分の動線(図-2)を例として説明する。この人物は図-1の右奥の横断歩道を右下から左上に向かっており、目視で映像を確認すると $x=7$ [m]付近および3[m]付近で対向歩行者を回避しているように観察される。この人物についての、各設定における歩行者位置の推定精度(図-3)、予測尤度の時系列変化(図-4)およびモデル混合率の時系列変化(図-5)を示す。これらの図を比較すると、たとえば予測誤差の小ささと予測尤度の大きさは必ずしも対応していないなど、結果からの考察方法についてはさらなる検討が必要である。以下では、それぞれの設定における特徴について述べる。

a) ガウス過程によるモデル

はじめに w_1 の初期分布を、 $w_1 \sim N(0, 0.1)$ と $w_1 \sim N(0.9, 0.1)$ との2種類設定する。これは、離散選択モデルを選択する確率 π_1 が50%および71%に相当する。また、式(4)において $\sigma=0.1$ とする。予測尤度は、3種類のモデルのなかでは安定的に高い値を示しているという特徴がある。モデルの混合率の時系列変化(図-5)に着目すると、他のモデルと比較すると値が安定的である。これらのことは、安定的な推定が可能であるという利点と考えられる一方で、行動分析という観点からはデータに対する感度が小さいため適していないという可能性もある。この点について、今後の検討事項としたい。

b) 遷移確率行列によるモデル

初期の π_1 は前節と同様に50%および71%を設定する。また、 C を以下のように設定する。

$$C = \begin{pmatrix} 0.9 & 0.1 \\ 0.1 & 0.9 \end{pmatrix} \quad (13)$$




図-2 動線の例

この設定における混合率の推定結果は大きく変動している(図-5)。マルコフ性を仮定しているために想定される結果ではあるものの、初期の π_1 によって変動の状況が異なっているようにもみえるなど、原因についてより詳細な検討が必要である。一方で、初期の π_1 に関わらず混合率は同じ程度の値に落ち着いてきているようにも見えるため、より長い時系列に適用してモデルの挙動を分析する必要がある。その結果として、仮に初期分布によらず混合率の時系列変動が安定的に推定されるのであれば、この方法の利点と考えられ、行動分析に繋がっていく可能性も高いモデルであるといえる。

c) 予測尤度によるモデルスイッチング

尤度低下を判定する閾値の設定は、前の時刻における予測尤度と現在の予測尤度との比が0.5または0.8を下回ったときに、モデルを切り替えるものとする。また、横断歩道での歩行行動は、横断開始時には対向歩行者との関係性が強いと想定されるため、最初のモデルは離散選択モデルに設定する。

まず、閾値が0.5のときはモデルスイッチングが行わ

グラフの色は以下を示している

- ・設定 a) 赤： $\pi_1=50\%$ / ピンク： $\pi_1=71\%$
- ・設定 b) 黄緑： $\pi_1=50\%$ / 緑： $\pi_1=71\%$
- ・設定 c) 青：閾値 0.5 / 水色：閾値 0.8

予測誤差[m]




図-3 歩行者位置の推定精度

予測尤度




図-4 予測尤度




図-5 離散選択モデルの選択割合

れず、常に離散選択モデルが選択された。一方、閾値 0.8 のときは、5 秒後に一度等速直線運動に切り替わり、8 秒後に再び離散選択モデルに戻った。離散選択モデルから等速直線運動へのスイッチング時刻は、 $x=7[m]$ 付近すなわち図-2 で軌跡が若干膨らみ歩行者が対向者を避けて方向転換を行ったときに一致する。このような発見を蓄積していけば、どの場所でどのような行動が起きるかの分析に繋がると思われる。ただし、角度変更行動はもともと尤度が低いため、偶然モデルの切り替えが行われたという解釈も可能であるなど慎重な分析が必要である。

5. まとめと今後の展望

本研究では、意思決定を明示的に変数に組み込むモデルを複数混合することにより、ミクロな歩行者挙動を表す方法を整理した。また、時系列データに対して簡単な推定を試行し、モデルの混合率や選択状況の把握可能性を示した。現時点では、3種類の混合方法を示し、それらの特徴の一端を仮説的に述べるにとどまっているが、今後データの蓄積や手法の洗練により、実際の歩行行動分析につながると考えている。

推定時の設定方法や適用例の蓄積以外の大きな検討事項として、以下があげられる。第一に、ミクロな歩行行動という事象そのものの前提について丁寧な検討を必要とする。たとえば、各歩行者のある瞬間の行動は単一のモデルで表現すべきか確率的に記述すべきかの検討により、本稿で示した方法のうちどれが適しているかの判断も変わる。第二に、本稿ではデータを時系列に与え逐次推定することを前提としたが、種々考えられるデータセットの扱い方の検討が必要である。たとえば、各歩行者のデータを動線として一括で扱い時系列を考慮しない場合は、自然言語処理で多く用いられるトピックモデルの枠組みとなる。このような、データの扱い方に対する推定結果の挙動についても分析の必要がある。

謝辞：本研究は科学研究費(若手研究B：15K18131)の助成により行われた。データ取得に際しては、東京大学の井料美帆講師および川崎モアーズにご協力いただいた。

参考文献

1) Antonini, G., Bierlaire, M. and Weber, M.: Discrete

- Choice Models of Pedestrian Walking Behavior, *Transportation Research Part B: Methodological*, Vol.40, No.8, pp.667-687, 2006.
- 2) 持橋大地：最近のベイズ理論の進展と応用[III] ノンパラメトリックベイズ，電子情報通信学会誌，Vol.93, No.1, pp.73-79, 2010.
- 3) Ishiguro, K., Yamada, T. and Ueda, N.: Simultaneous Clustering and Tracking Unknown Number of Objects, *2008 IEEE Conference on Computer Vision and Pattern Recognition*, pp.1-8, 2008.
- 4) 時永祥三，池田欽一：非線形時系列モデルにおける粒子フィルタおよび遺伝的プログラミングを用いた構造変化の推定，電子情報通信学会技術研究報告 NLP, Vol.110, No.465, pp.117-122, 2011.
- 5) 渡辺澄夫：ベイズ統計の理論と方法，コロナ社，2012.
- 6) Choudhury, C., Ben-Akiva, M. and Abou-Zeid, M.: Dynamic Latent Plan Models, *Journal of Choice Modelling*, Vol.3, No.2, pp.50-70, 2010.
- 7) 中西航，高橋真美，布施孝志：歩行者挙動モデルパラメータ推定への一般状態空間モデルの適用，土木計画学研究・講演集，Vol.49, CD-ROM, 2014.
- 8) Kim, C.J. and Nelson, C.R.: *State-Space Models with Regime Switching: Classical and Gibbs-Sampling Approaches with Applications*, The MIT Press, Cambridge, 1999.
- 9) 山西健司：データマイニングによる異常検知，共立出版，2009.
- 10) 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.
- 11) Gordon, N., Salmond, D. and Smith, A.: Novel Approach to Nonlinear/non-Gaussian Bayesian State Estimation, *Radar and Signal Processing, IEE Proceedings F*, Vol.140, No.2, pp.107-113, 1993.
- 12) 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.
- 13) Casella, B.Y.G. and Robert, C.P.: Rao-Blackwellisation of Sampling Schemes, *Biometrika*, Vol.83, No.1, pp.81-94, 1996.
- 14) Doucet, A., De Freitas, N., Murphy, K. and Russell, S.: Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks, *Proceedings of the Sixteenth Conference on Uncertainty in Artificial Intelligence*, pp.176-183, 2000.
- 15) 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.

(2015.7.31 受付)

MIXTURE MODEL FORMULATION TOWARD MICROSCOPIC PEDESTRIAN BEHAVIOR ANALYSIS

Wataru NAKANISHI and Takashi FUSE