

# 観測不確実性下における 経路選択モデルの不動点問題

大山雄己<sup>1</sup>・羽藤英二<sup>2</sup>

<sup>1</sup>学生会員 東京大学／日本学術振興会特別研究員 DC (〒 113-8656 東京都文京区本郷 7-3-1)

E-mail: oyama@bin.t.u-tokyo.ac.jp

<sup>2</sup>正会員 博士 (工学) 東京大学 (〒 113-8656 東京都文京区本郷 7-3-1)

E-mail: hato@bin.t.u-tokyo.ac.jp

位置情報の点列からの経路観測には不確実性が伴う。経路選択モデルはマップマッチングをはじめとした経路観測モデルから得られる経路情報をインプットとし、行動メカニズムを表すパラメータを推定する。経路情報に何らかのバイアスが含まれる場合、バイアスの残ったパラメータが推定値として得られることになる。本研究では経路観測の不確実性に着目し、そのバイアスを取り除くため、経路観測モデルを内生化した経路選択モデルの推定手法を提案する。また、経路観測モデルとしてリンクベースの手法を提案し、従前モデルが抱えていた選択肢集合と観測の誤差分散に関する課題の解決を試みる。双子実験・実データによるケーススタディは本手法を有効性を示した。

**Key Words :** Route choice model, Structural estimation, Map-matching

## 1. はじめに

経路選択行動メカニズムの統計的検証を目的とした経路選択モデルのパラメータ推定には、選択結果として実際の経路情報が必要である。経路はネットワーク上のリンクの組み合わせとして記述されるため、聞き取り調査による観測は難しく、一般的にマップマッチング手法を通じて観測される。マップマッチングは、GPSに代表される位置と時刻の情報を持った点列をネットワーク上に載せ、経路という意味のある情報へと変換する手法であり、これまでに多くの手法が提案されてきている。しかし、本来ネットワーク上にない点データを分析者が恣意的に設定したネットワークに落とし込める以上、経路の観測は確実ではなく、特にネットワーク密度が高く、空間解像度が高い状況では未だ観測の不確実性が大きい。不確実な観測結果を用いて経路選択モデルのパラメータを推定することで、得られるパラメータ推定値にもバイアスが残ると考えられる。

Bierlaire and Frejinger (2008)<sup>5)</sup>は、観測の不確実性を明示的に考慮するため、誤差を持つ1つの観測データが紐付けられ得る空間的な範囲を *Domain of Data Relevance* (DDR) として定義し、データの正規化を必要としない経路選択モデルを提案した。また近年では、一般状態空間モデルを用いた確率的な空間選択行動の観測モデルも提案されている (布施・中西, 2012<sup>10)</sup>; Bierlaire et al., 2013<sup>4)</sup>; Danalet et al., 2014<sup>8)</sup>; Chen and Bierlaire, 2015<sup>7)</sup>)。一般状態空間モデルは直接観測で




図-1 一般状態空間モデル

きな状態の遷移を推定する手法であり、状態ベクトル  $a_n$  と観測ベクトル  $\hat{m}_n$  から構成される (図-1)。これらのベクトルに基づいて、観測方程式  $p(\hat{m}_n | a_n; \sigma)$  およびシステム方程式  $p(a_n | a_{n-1}; \theta)$  が条件付き分布として定義される。本来観測したい状態の遷移を記述するシステム方程式は行動モデルに他ならず、経路選択モデル<sup>4),7)</sup>や目的地選択モデル<sup>10),8)</sup>が用いられる。観測ベクトル  $\hat{m}_n$  が与えられたときに真の状態ベクトルが  $a_n$  である確率は、ベイズの公式を用いて、

$$p(a_n | \hat{m}_{1:n}) \propto p(\hat{m}_n | a_n; \sigma) p(a_n | \hat{m}_{1:n-1}) \quad (1)$$

のように分解され、 $p(a_n | \hat{m}_{1:n-1})$  は再帰的に、

$$p(a_n | \hat{m}_{1:n-1}) = \int p(a_n | a_{n-1}; \theta) p(a_{n-1} | \hat{m}_{1:n-1}) da_{n-1} \quad (2)$$

となる。事後確率  $p(a_n | \hat{m}_n)$  を用いて、状態経路である  $\psi = [a_1, \dots, a_n, \dots, a_N]$  が推定される<sup>10),8)</sup>。しかしこれ

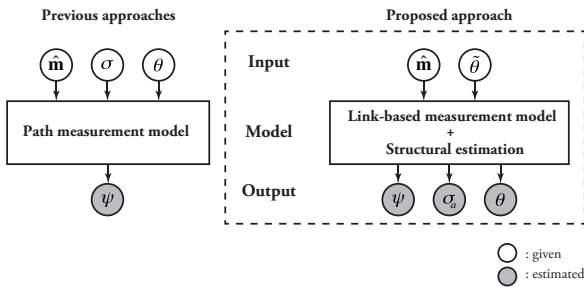


図-2 提案モデルのフレームワーク

までに発表されている一般状態空間モデルを用いた状態推定手法では、観測方程式・システム方程式のパラメータ  $\sigma, \theta$  は所与とされるため、パラメータの初期設定に関するバイアスを含んだ形で状態が推定されるという課題を残している (図-2 左)。観測方程式のパラメータ  $\sigma$  は、位置情報が持つ機器依存の観測誤差分散を意味することが多い。位置情報の精度は広幅員街路で高く、ストリートキャニオンや建築内部では大きくばらつくといったように、調査対象者の活動空間に大きく依存することが知られている。しかし既往研究ではネットワーク全体で一定かつ所与のパラメータとして設定されることが多く<sup>4),7),8)</sup>、空間による誤差分散の違いを考慮しないことによって観測結果が歪むと考えられる。また、位置情報の不確実性が高い、あるいはネットワークが高密度な状況ではシステム方程式への依存度が高まり、行動パラメータである  $\theta$  の誤差が観測結果に大きなバイアスを与える可能性がある。

初期パラメータに依存するバイアスを含んだ状態で観測モデルによって出力される行動情報を、行動モデル推定のデータ・セットとして用いることで、経路選択モデルを通じて最終的に求めたい行動パラメータの推定値にもバイアスが残ってしまうことになる。このバイアスを取り除くため、本研究では観測の不確実性を考慮し、経路選択モデルのパラメータを不動点として求めるためのフレームとその解法を提案する。また、パスベースの経路選択モデルおよび経路観測が、選択肢 (候補) 集合の生成に課題を残していることに着目し、リンクベースの逐次経路観測モデルを提案する。手法は後述するが、観測モデル内に含まれる時間構造化操作によって、位置情報の誤差分散をリンク固有変数として推定することが可能となる。つまり、本研究ではパラメータ  $\sigma, \theta$  をいずれも所与とすることなく、モデルを通じて出力可能とする (図-2 右)。これによってパラメータ設定に依存したバイアスを除去し、経路選択モデルのパラメータ推定精度を向上させることを目的としたい。




図-3 リンクベース経路観測モデルのフロー

論文の構成は以下である。2章において、リンクベースの経路観測手法の導入と式の導出を行なう。3章では、観測モデルを内生化した経路選択モデルとその推定手法を提示する。双子実験によるモデルの有効性検証、そして実データへの適用を4章で行い、最後に結論と今後の課題を述べる。

## 2. リンクベース経路観測モデル

本章では、一般状態空間モデルを用いたリンクベースの経路観測モデルを提案する。

### (1) データの時間構造化

ネットワークを  $G = (V, A)$  とする。  $V, A$  はそれぞれノード (頂点)、リンク (辺) の集合である。各ノード  $v \in V$  は属性として、緯度・経度で記述される位置座標  $x_v = \{x_{vlat}, x_{vlon}\}$  を持つ。リンク  $a \in A$  は始点・終点の組  $(v_u, v_d)$  で特徴づけられる。各リンクの空間的特性を表す属性変数ベクトルを  $y_a$  とする。また、リンク  $a$  の終点  $v_d$  を始点として持つ後続リンクの集合を  $A(a)$  と定義する。リンク間の接続関係は変数  $\delta(a'|a)$  を用いて定義し、リンク  $a, a' \in A$  が接続している ( $a' \in A(a)$ ) のとき  $\delta(a'|a) = 1$ 、それ以外るとき  $\delta(a'|a) = 0$  となる。

本研究では、(交通手段に関係なく) 旅行者の携帯機器に内挿されたセンサから得られるデータを用いる。経路観測モデルは、この位置と時刻の情報を持った点列をネットワーク上に載せ、経路という行動論的に意味のある情報へと変換する。各観測点を  $\hat{m} = (\hat{x}, \hat{\tau})$  とする。  $\hat{x} = (\hat{x}_{lat}, \hat{x}_{lon})$  は位置座標を表す緯度・経度の組、  $\hat{\tau}$  は観測時刻である。ある (交通手段変更を含まない) トリップに対して、時系列順に並ぶ点列  $\hat{\mathbf{m}} = (\hat{m}_1, \dots, \hat{m}_n, \dots, \hat{m}_N)$  が得られていると仮定する。

リンクベースの経路観測モデルのフローを図-3に示す。まず、一定の幅を持った時間の列  $(1, \dots, t, \dots, T)$  を定義する。つまり、すべて  $t = \{t^-, t^+\}$  において、時間幅  $\bar{t} = t^+ - t^-$  は一定である。  $\bar{t}$  はネットワークご

とに定義する変数であり、基本的にはリンクの接続条件を満たすよう、リンク長  $L_a$  および対象とする交通手段の平均速度  $v_{ave}$  を用いて  $\bar{t} = (\min_a L_a)/v_{ave}$  とする。時間  $t$  内に含まれる ( $t^- \leq \hat{\tau}_j^t \leq t^+$  を満たす) 観測の列を、 $\hat{\mathbf{m}}^t = (\hat{m}_1^t, \dots, \hat{m}_j^t, \dots, \hat{m}_J^t)$  と定義し、 $\hat{\mathbf{m}}$  を  $(\hat{\mathbf{m}}^1, \dots, \hat{\mathbf{m}}^t, \dots, \hat{\mathbf{m}}^T)$  のように時間ごとの観測組に分解する。本研究では、同時間内に含まれるすべての観測点が、同じリンクに属するという仮定に基づいて、 $t = 1$  から順番に逐次的なリンクの観測を行なう。

## (2) 逐次経路観測モデル

本研究では、図-1 の状態空間モデルにおける状態ベクトルはリンク  $a_t \in A$ 、観測ベクトルは点列  $\hat{\mathbf{m}}^t$  に対応する。観測方程式  $p(\hat{\mathbf{m}}^t | a_t)$  は真の状態がリンク  $a_t$  であるときの観測  $\hat{\mathbf{m}}^t$  の尤もらしさを、システム方程式はリンク  $a_{t-1}$  から  $a_t \in A(a_{t-1})$  の遷移確率をそれぞれ表す。時間  $t$  に観測列  $\hat{\mathbf{m}}^t$  が得られたとき、真の状態が  $a_t$  である確率を、式 (1) を用いて以下のように定式化する。

$$p(a_t | \hat{\mathbf{m}}^t, a_{t-1}) \propto p(\hat{\mathbf{m}}^t | a_t; \sigma_{a_t}) p(a_t | a_{t-1}; \theta). \quad (3)$$

状態ベクトル  $a_t$  は離散的な状態を表すため、式 (3) は以下のように正規化を行なうことが可能である。

$$p(a_t | \hat{\mathbf{m}}^t, a_{t-1}) = \frac{p(\hat{\mathbf{m}}^t | a_t; \sigma_{a_t}) p(a_t | a_{t-1}; \theta)}{\sum_{a'_t \in A(a_{t-1})} p(\hat{\mathbf{m}}^t | a'_t; \sigma_{a'_t}) p(a'_t | a_{t-1}; \theta)} \quad (4)$$

真の状態  $a_t$  は以下の事後確率最大化によって推定される。

$$a_t = \arg \max_{a_t \in A(a_{t-1})} p(a_t | \hat{\mathbf{m}}^t, a_{t-1}). \quad (5)$$

この操作を  $t = 1$  から  $t = T$  まで繰り返すことによって、最終的に経路  $\psi = [a_1, \dots, a_t, \dots, a_T]$  が推定される (図-3)。

## (3) システム方程式

経路観測モデルにおけるシステム方程式は、観測の不確実性が大きい状況 (センサ強度が弱い場合、高密度なネットワークなど) において大きな意味を持つ。経路ベースの確率的経路観測モデル<sup>18),4),7)</sup>では、観測の過程および経路選択確率 (e.g., Path-size logit<sup>3)</sup>; C-logit<sup>6)</sup>) の算出において経路候補集合の限定が必要であり、重要な経路が捨象されてしまう恐れがある。候補集合を大きくすれば逆に計算負荷が大きくなり、現実的なネットワークへの適用が難しくなるという課題がある<sup>4),8)</sup>。

一方、本論文で提案するリンクベースの逐次経路観測モデルでは、システム方程式としてリンク間遷移確

率の評価を必要とする。マルコフ連鎖に基づくリンクベースの経路選択モデルは経路列挙を必要とせず、あらゆる経路を考慮することが可能である。最も単純には、近視眼的な行動を仮定し、一次マルコフ連鎖によって歩行者の経路選択行動を記述したモデル<sup>16)</sup>がある。また、Fosgerau et al.(2013)<sup>9)</sup>による *Recursive Logit model* (RL) は、マルコフ連鎖配分<sup>2),1)</sup>の考え方を応用して動的離散選択モデル<sup>19)</sup>による記述を行なうことで、リンク間遷移確率によって経路ベースの経路選択モデルと整合的な行動を記述でき、かつ選択肢集合を限定しないという利点を持つ。空間割引率の導入によって両者を一般化したモデル<sup>15)</sup>や、RL モデルに経路関連の記述を加えた手法<sup>14)</sup>、時間制約を導入したモデル<sup>17)</sup>も存在する。以上のようなリンクベースの経路選択モデルを用いてシステム方程式を記述することによって、観測経路の候補集合と、選択モデルの選択肢集合で整合性を失わない点が本観測手法の特徴である。

つまり、本モデルのシステム方程式には以下のリンク選択モデルを用いる。

$$p(a_t | a_{t-1}; \theta) = \mathbb{P}(u_{a_t}(\theta) \geq \max_{a_{t'} \in A(a_t)} u_{a_{t'}}(\theta)) \quad (6)$$

## (4) 観測方程式

時刻には観測誤差がないと仮定すれば、真の状態がリンク  $a_t$  であるときに観測列  $\hat{\mathbf{m}}^t = (\hat{m}_1^t, \dots, \hat{m}_J^t)$  が得られる確率は以下のように表される。

$$p(\hat{m}_1^t, \dots, \hat{m}_J^t | a_t; \sigma_{a_t}) = p(\hat{x}_1^t, \dots, \hat{x}_J^t | a_t; \sigma_{a_t}). \quad (7)$$

また、旅行者は同一リンク上をホワイトノイズを持つ等速直線運動し、リンク上の位置はリンクに到達してからの経過時間によってのみに決まると仮定すれば、式 (7) は以下のように分解される。

$$\begin{aligned} p(\hat{x}_1^t, \dots, \hat{x}_J^t | a_t; \sigma_{a_t}) &= \prod_{j=1}^J p(\hat{x}_j^t | a_t; \sigma_{a_t}) \\ &= \prod_{j=1}^J \int_{x_j \in a_t} p(\hat{x}_j^t | x_j, a_t; \sigma_{a_t}) p(x_j | a_t) dx_j \end{aligned} \quad (8)$$

where,

$$x_j = lx_{vd} + (1-l)x_{vu}, \quad (9)$$

$$l = \frac{\hat{\tau}_j^t - t^-}{t^+ - t^-} + \eta, \quad (10)$$

$$\eta \sim N(0, \sigma_\eta^2). \quad (11)$$

$p(\hat{x}_j^t | x_j, a_t; \sigma_{a_t})$  は位置情報の観測誤差に依存する確率である。GPS 位置情報の水平誤差は一般に独立正規分布に従うことが知られており<sup>20)</sup>、それゆえ真の位置と観測点の水平距離  $d$  はレイリー分布に従う。そのため、




図-4 経路観測の失敗例

リンク  $a_t$  上に存在する位置  $x_j$  が観測点  $\hat{x}_j^t$  を生成する確率  $p(\hat{x}_j^t | x_j, a_t; \sigma_{a_t})$  は、

$$p(\hat{x}_j^t | x_j, a_t; \sigma_{a_t}) = \frac{\|\hat{x}_j^t - x_j\|}{\sigma_{a_t}^2} \exp\left(-\frac{\|\hat{x}_j^t - x_j\|^2}{2\sigma_{a_t}^2}\right). \quad (12)$$

である。  $\sigma_{a_t}^2$  は誤差分散パラメータであり、ネットワーク由来の誤差と機器依存の誤差から構成される<sup>4),?)</sup>。従前の観測モデルでは、誤差分散はネットワーク上で一定の値として扱われることによって、観測確率に歪みを生じさせていた。しかし本研究で提案するリンクベースの経路観測モデルは、リンク  $a \in A(a_{t-1})$  の固有変数として誤差分散のパラメータを評価することが可能であり、  $\sigma_{a_t}$  は以下の観測尤度最大化によって推定される。

$$\sigma_{a_t} = \arg \max_{\sigma} p(\hat{\mathbf{m}}^t | a_t; \sigma), \quad (13)$$

推定された  $\sigma_{a_t}$  を式 (5) に代入し、リンク  $a_t$  の事後確率を評価する。

### (5) リンクスイッチング

逐次的なリンクの観測が持つ問題として、一度の観測の失敗が後続の観測に影響を与えてしまうことが挙げられる。図-4に一例を示す。観測モデルを通じて、まず  $t=1$  の状態としてリンク  $a_1=2$  が推定され、  $t=2$  におけるリンク候補集合は  $A(a_1=2) = \{2, 4, 5, 7\}$  である。各リンクの観測確率  $p(a_2 | \hat{\mathbf{m}}^2, 2)$  を計算し、リンク 4 が推定されたとする。ここで、  $t=3$  のリンク候補集合は  $A(a_2=4) = \{1, 3, 4, 6\}$  であるものの、観測列  $\hat{\mathbf{m}}^3 = (\hat{m}_1^3, \hat{m}_2^3, \hat{m}_3^3)$  に着目すれば、  $A(a_2)$  に尤もらしいリンクが含まれないことが考えられる。しかし、  $t=2$  でリンク 4 が推定されたことで  $t=3$  の状態としてリンク 6 が推定される。つまりこの例は、本来推定されるべき経路が点線で表される  $\psi = [2, 7, 10]$  であつたにも関わらず、  $t=2$  における観測の失敗が影響し、観測列  $(\hat{\mathbf{m}}^1, \hat{\mathbf{m}}^2, \hat{\mathbf{m}}^3)$  に対して、太線の経路  $\psi = [2, 4, 6]$  が推定されてしまったケースを示している。

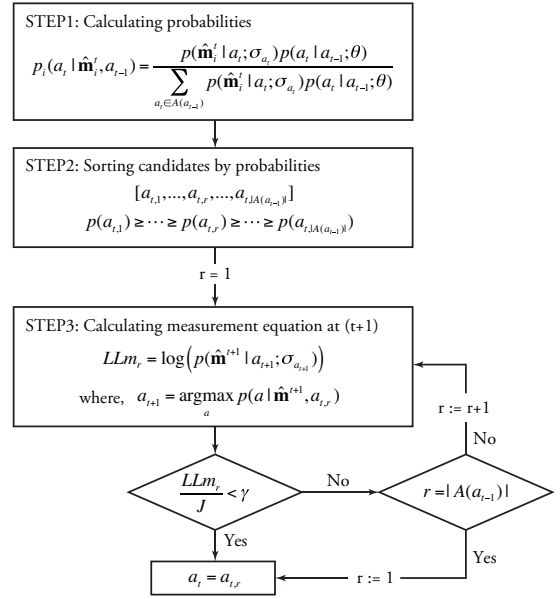


図-5 リンクスイッチングアルゴリズム

この問題に対処するため、リンクスイッチングアルゴリズム (図-5) を提案する。アルゴリズムは以下のステップに従う。

Step 1: 時点  $t$  において、全ての候補リンク  $a_t \in A(a_{t-1})$  に対して式 (5) に基づく事後確率  $p(a_t | \hat{\mathbf{m}}^t, a_{t-1})$  を計算する。

Step 2: 事後確率順に候補リンクを並び替え、  $[a_{t,1}, \dots, a_{t,|A(a_{t-1})|}]$  のようにラベリングを行なう。このとき、以下の関係式を満たす必要がある。

$$p(a_{t,1} | \hat{\mathbf{m}}^t, a_{t-1}) \geq \dots \geq p(a_{t,r} | \hat{\mathbf{m}}^t, a_{t-1}) \geq \dots \geq p(a_{t,|A(a_{t-1})|} | \hat{\mathbf{m}}^t, a_{t-1}). \quad (14)$$

Step 3:  $r=1$  とする。時点  $t$  の状態ベクトルを  $a_{t,r}$  とし、時点  $t+1$  における候補リンク  $a_{t+1} \in A(a_{t,r})$  の最大観測尤度  $LLm_r$  を計算する。

$$LLm_r = \log(p(\hat{\mathbf{m}}^{t+1} | a_{t+1}; \sigma_{a_{t+1}})), \quad (15)$$

where,

$$a_{t+1} = \arg \max_a p(a | \hat{\mathbf{m}}^{t+1}, a_t). \quad (16)$$

Step 4: 以下の不等式が満たされれば時点  $t$  の状態ベクトルを  $a_t = a_{t,r}$  とし、そうでない場合は Step 5 に進む。

$$\frac{LLm_r}{J} > \gamma, \quad (17)$$

Step 5:  $r = |A(a_{t-1})|$  であれば時点  $t$  の状態ベクトルを  $a_t = a_{t,1}$  とする。そうでない場合、  $r = r+1$  として Step 3 へ戻る。



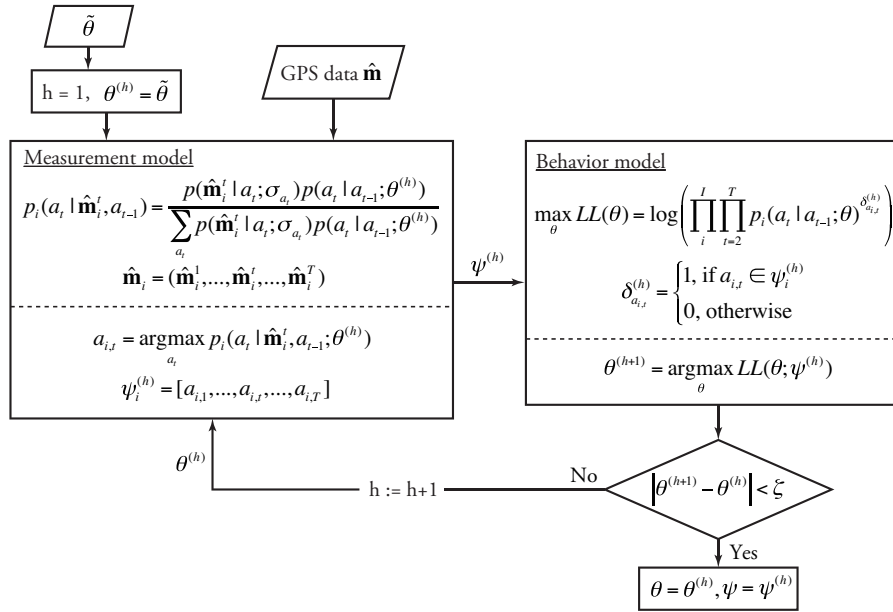


図-6 構造推定

### 3. 構造推定

経路選択モデルにおいて、観測モデルを通じて得られた経路情報は経路選択行動パラメータの推定におけるデータ・セットとして用いられる。本章では、両モデルの関係性に着目し、観測モデルを内生化した経路選択モデルのフレームワークを提示し、その解法としての構造推定手法を提案する。

#### (1) 経路選択モデル

経路選択モデルのパラメータ推定には、一般的に最尤推定法が用いられる。対数尤度関数はパラメータベクトル  $\theta$  の関数として、以下のように定式化される。

$$\begin{aligned}
 LL(\theta) &= \log \left( \prod_i \prod_{t=2}^T p(a_t | a_{t-1}; \theta)^{\delta_{a_t}^i} \right) \\
 &= \sum_i \sum_{t=2}^T \delta_{a_t}^i \log(p(a_t | a_{t-1}; \theta)), \quad (18)
 \end{aligned}$$

ここで、 $\delta_{a_t}^i$  は経路  $i$  の  $t$  番目のリンクが  $a_t$  であれば 1、それ以外で 0 となる変数である。 $p(a_t | a_{t-1}; \theta)$  は前章で紹介したリンクベースの経路選択モデルから得られるリンク間遷移確率であり、観測モデルのシステム方程式に一致する。対数尤度関数を最大化させるパラメータとして、 $\theta$  は推定される。

$$\theta = \arg \max_{\theta} LL(\theta). \quad (19)$$

ここで、動的離散選択に基づく経路選択モデル<sup>7),14),15)</sup>

の場合は通常の推定手法が適用できず、NFXP アルゴリズム<sup>19)</sup>を用いる。

#### (2) 構造推定のアルゴリズム

状態空間モデルを用いた観測モデルは、本来独立である経路選択モデルのパラメータをシステム方程式内に含んでいる。経路を観測する段階で  $\theta$  の真値はわからないため、既往研究では他の調査から得られた推定パラメータ<sup>10),7)</sup>や任意の値<sup>8)</sup>として与えることが多く、全く情報がない場合には一様分布とされる場合もある<sup>7),13)</sup>。しかし、いずれの場合においても推定しようとする経路選択モデルのパラメータとは異なることは明らかであり、観測経路および推定パラメータにバイアスを含んでしまうことになる。本研究では、 $\theta$  が観測・行動モデルに共通のパラメータであることに着目し、観測モデルを内生化させた経路選択モデルの推定手法を提案する。構造推定アルゴリズム (図-6) は以下のステップに従う。

- Step 1: **初期化.** 観測  $\hat{\mathbf{m}}$  及び初期パラメータ  $\tilde{\theta}$  をセットし、 $h = 1$  とする。
- Step 2: **経路推定.** リンクベースの観測モデル (2 章) を通じてリンク誤差分散  $\sigma_a$  および経路  $\psi$  を推定する。 $\psi^{(h)} = \psi$  とする。
- Step 3: **経路選択モデルの推定.**  $\psi^{(h)}$  をデータ・セットとし、最尤推定法によってパラメータ  $\theta$  を推定する。 $\theta^{(h+1)} = \theta$  とする。
- Step 4: **収束判定.** 以下の不等式を満たせば終了し、 $\theta = \theta^{(h+1)}$  とする。そうでない場合、 $h = h + 1$  と

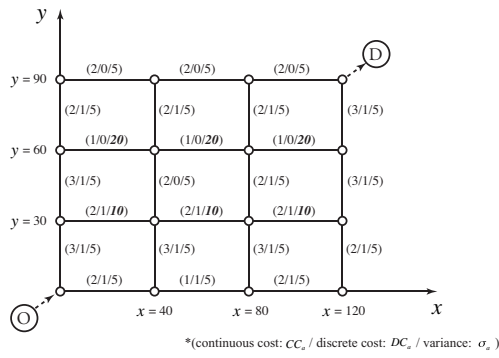


図-7 シンプルネットワーク

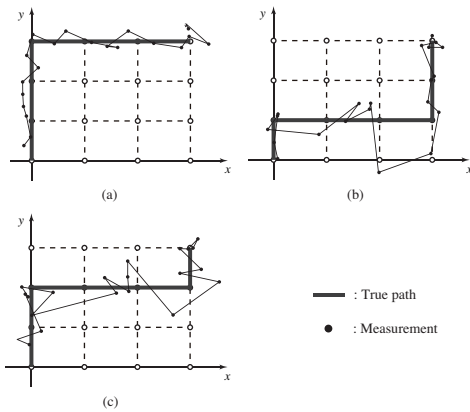


図-8 異なる  $\sigma_a$  を持つ経路のサンプリング

して Step 2 へ戻る.

$$|\theta^{(h+1)} - \theta^{(h)}| < \xi \quad (20)$$

## 4. 数値計算

### (1) 双子実験

図-7のシンプルネットワークを用いて、提案手法の有効性を検証する。ネットワーク上の括弧内の数字はそれぞれ、リンクコスト（連続変数） $CC_a$ 、リンクコスト（1 or 0） $DC_a$ 、リンク依存の誤差分散  $\sigma_a$  を表している。誤差分散は基本的に  $\sigma = 5$  であり、 $y = 60, 30$  のリンクのみ  $\sigma = 20, 10$  としている。図-8は誤差分散の異なる経路を通過した場合に生成される位置情報をプロットしたものであり、分散の大きなリンクを通過する経路(b)および(c)では、観測点が大きくバラついていることがわかる。シミュレーションでは歩行者を想定し、以下の1次マルコフ連鎖に基づくリンク選択モデルを用いる。

$$p(a'|a; \theta) = \frac{\exp(v(a'|a))}{\sum_{a' \in A(a)} \exp(v(a'|a))} \quad (21)$$

パラメータの真値を  $\tilde{\theta} = [-0.1, -2, -1.5, -4]$  とし、リンクの効用関数を以下で定義する。

$$v(a'|a) = \theta_1 TT_{a'} + \theta_2 CC_{a'} + \theta_3 DC_{a'} + \theta_4 UT_{a'|a} \quad (22)$$

$TT_a$  はリンク旅行時間（秒）であり、 $UT_{a'|a}$  はUターンのダミー変数である。式(21)(23)を用いて、時間幅  $\bar{t} = 30s$ 、観測間隔  $\hat{\tau}_n - \hat{\tau}_{n-1} = 10s$  としてシミュレーションを行なった。

複数のモデルを用いて経路の観測を行なった結果として、リンクの観測精度および  $\sigma$  の推定誤差を表-1に示す。 $\sigma$  の推定誤差は以下の式で計算した。

$$\frac{1}{|I||T|} |\sigma_{a,est} - \sigma_{a,true}|, \quad (23)$$

$|I||T|$  はサンプル数（リンクの観測数）である。 $\sigma_a = 20$  ( $\forall a \in A$ ) を所与とし、観測方程式のみでリンクを推定した場合（Model 1）のリンク正答率は 54.571%であった。Model 2の結果との比較から、ネットワーク上で  $\sigma$  にバラつきがある場合には、 $\sigma$  を所与とせず推定することで観測精度が上昇することが示された。また、全てのモデルにおいて、スイッチングアルゴリズムを導入することでリンクの正答率、 $\sigma$  の推定精度が共に上昇しており、アルゴリズムの有効性が伺える。Model 3,4,5はシステム方程式として、異なるパラメータの値を持つリンクの選択確率を導入したモデルである。表-1の結果は、パラメータ  $\theta$  が真値に近い場合には推定精度が大幅に向上する（Model 5 + Switchingで 91.714%）一方、真値から大きく外れた値を持つ場合（Model 4）は、システム方程式の導入によりかえって推定精度が下がってしまうことを示している。つまり、初期値に含まれるバイアスを取り除くための構造推定手法の必要性がここから伺える。

Model 3,4,5を用いて観測した経路情報をもとに、経路選択モデルを推定したときの結果を表-2に示す。表中の”One-way”は初期パラメータ  $\tilde{\theta}$  を用いた経路の観測と、その観測結果を用いた経路選択モデルの推定を一度ずつのみ行なったときの結果を示している。”Structural estimation”は図-6の構造推定を用いて、 $\theta$  が収束するまで計算を繰り返したときの結果を示している。 $\tilde{\theta} = [0, 0, 0, 0]$  (no information) および  $\tilde{\theta} = [-1.5, -0.1, -2, -10]$  のとき、”one-way”の推定結果は真値との差がそれぞれ 3.643, 6.058であり、大きくずれた結果となった。正負の逆転も見られ、修正済み尤度比  $\rho^2$  の観点からも良い推定結果とはいえない。反対に、”Structural estimation”の結果はより真値に近

表-1 リンク正答率および  $\sigma$  推定誤差

	Model	$\sigma$	$\theta$	accuracy(%)		Ave. $ \sigma_{est} - \sigma_{true} $	
				-	Switching	-	Switching
1	MEQ	given	-	54.571	68.857	-	-
2	MEQ	estimated	-	76.857	82.857	5.848	4.397
3	MEQ+SEQ	estimated	[0, 0, 0, 0]	76.857	82.857	5.848	4.397
4	MEQ+SEQ	estimated	[-1.5, -0.1, -2, -10]	4.857	38.286	41.992	21.206
5	MEQ+SEQ	estimated	[-0.1, -2, -1.5, -4]	76.857	91.714	7.579	4.056

\*MEQ: Measurement Equation  
\*SEQ: System Equation

表-2 経路選択モデルのパラメータ推定結果

Input: $\tilde{\theta} = [0, 0, 0, 0]$ (No information)							
	One-way				Structural Estimation		
	TRUE	Estimates	abs(diff.*)	t-value	Estimates	abs(diff.)	t-value
$\theta_1$	-0.1	0.002	0.102	0.101	-0.064	0.036	-2.562
$\theta_2$	-2	-0.755	1.245	-4.164	-1.727	0.273	-6.882
$\theta_3$	-1.5	-1.312	0.188	-4.772	-1.046	0.454	-3.519
$\theta_4$	-4	-1.892	2.108	-8.864	-3.519	0.481	-9.739
total error			3.643			1.244	
sample				350			350
L0				-373.221			-371.887
LL				-269.872			-211.308
$\rho^2$				0.266			0.421
iteration							6

Input: $\tilde{\theta} = [-1.5, -0.1, -2, -10]$ (Wrong values)							
	One-way				Structural Estimation		
	TRUE	Estimates	abs(diff.)	t-value	Estimates	abs(diff.)	t-value
$\theta_1$	-0.1	-0.097	0.003	-5.312	-0.064	0.036	-2.562
$\theta_2$	-2	-0.419	1.581	-2.710	-1.727	0.273	-6.882
$\theta_3$	-1.5	0.178	1.678	0.963	-1.046	0.454	-3.519
$\theta_4$	-4	-1.204	2.796	-6.774	-3.519	0.481	-9.739
total error			6.058			1.244	
sample				350			350
L0				-373.560			-371.887
LL				-328.587			-211.308
$\rho^2$				0.110			0.421
iteration							8

Input: $\tilde{\theta} = [-0.1, -2, -1.5, -4]$ (TRUE values)							
	One-way				Structural Estimation		
	TRUE	Estimates	abs(diff.)	t-value	Estimates	abs(diff.)	t-value
$\theta_1$	-0.1	-0.075	0.025	-2.932	-0.070	0.030	-2.762
$\theta_2$	-2	-1.816	0.184	-7.111	-1.772	0.228	-7.014
$\theta_3$	-1.5	-1.010	0.490	-3.405	-1.022	0.478	-3.462
$\theta_4$	-4	-3.469	0.531	-9.754	-3.448	0.552	-9.766
total error			1.230			1.288	
sample				350			350
L0				-371.193			-371.193
LL				-211.614			-211.798
$\rho^2$				0.419			0.419
iteration							3

\*diff: the difference from the true value

い値を示しているだけでなく、どちらのケースにおいても  $\tilde{\theta}$  によらず同じ収束値をとることがわかった。さらに、t 値や  $\rho^2$  にも改善が見られたことから、構造推定の有効性が示されたといえよう。一方、真値を初期値とした  $\tilde{\theta} = [-0.1, -2, -1.5, -4]$  (TRUE values) の場

合では、構造推定の結果が”One-way”に比較して悪くなっている。しかし、パラメータ推定値、t 値、 $\rho^2$  いずれも誤差は大きくなく、実際の状況を考えればパラメータの真値は知り得ないため、真値を用いた時の結果に近い結果を出力できる構造推定手法には大きな意

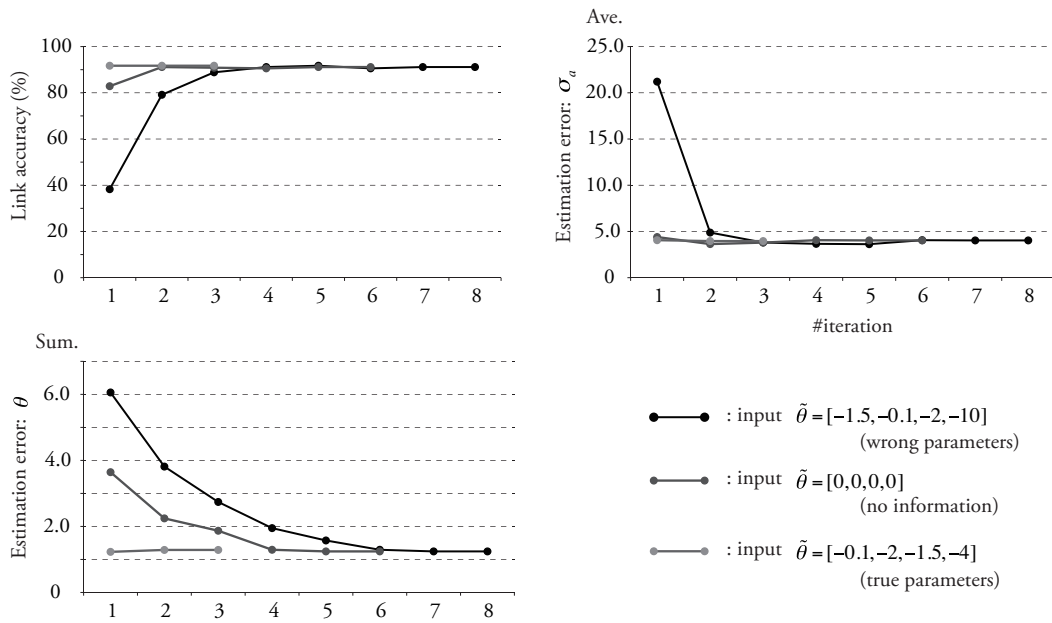


図-9 収束過程におけるリンク正答率およびパラメータ推定誤差の変化




図-10 松山 PP 調査から抽出した歩行者データのプロット

味があると考えられる。

また、リンクの正答率、 $\sigma$  および  $\theta$  の真値からのズレが収束の仮定でどのように変化したかを図-9 に示す。 $\hat{\theta}$  に関係なく、リンクの正答率は 90% 以上に収束した。また、 $\sigma$ 、 $\theta$  も収束の過程で真値に近づく様子が見られる。つまり今回の結果では、行動パラメータ  $\theta$  を収束させることによって経路  $\psi$  や観測誤差分散  $\sigma$  の値が寧ろ悪くなるといったケースは見受けられず、それぞれのパラメータが相互に関係しあってバイアスを少なくする方向へ向かったことがわかる。

表-3 実データを用いた構造推定結果

Input:  $\hat{\theta} = [0, 0, 0, 0]$  (No information)

	One-way		Structural Estimation	
	Estimates	t-value	Estimates	t-value
$\theta_1$	-0.007	-2.473	-0.001	-0.428
$\theta_2$	0.088	1.497	0.134	1.582
$\theta_3$	-0.004	-0.011	2.760	4.288
$\theta_4$	0.774	0.532	0.469	3.344
sample	270		270	
L0	-307.608		-309.066	
LL	-302.174		-225.162	
$\rho^2$	0.005		0.259	
iteration	11			

表-4 観測パラメータの推定結果

	Average	Variance
$\sigma_a$	31.622	941.021

(2) ケーススタディ

最後に、提案手法を実データに適用する。用いるデータは、松山市を対象に行われたプローブパーソン（以下、PP）調査<sup>12),11)</sup>から得られたデータである。中心市街地を訪れた歩行者の GPS データ（図-10）を対象に分析を行なった。

モデルとしては、前節のシミュレーションと同様 1 次マルコフ連鎖に基づくリンク選択モデルを用いる。歩行者がリンク  $k$  から  $a$  に移動する際の効用を、以下の



ように設定する。

$$v(a|k) = \theta_1 TT_a + \theta_2 CU_a + \theta_3 DU_a + \theta_4 UT_{a|k} \quad (24)$$

ここで、 $CU_a$  はリンク  $a$  の歩道幅員 (m)、 $DU_a$  はアーケードダミー変数とする。初期値を  $\tilde{\theta} = [0, 0, 0, 0]$  とし、無作為に 30 人の個人 (792 の位置データ) を抽出して推定を行なった結果を表-3 に示す。"One-way" の結果と比較して、構造推定の結果は  $t$  値、 $\rho^2$  の観点からも向上が見られる。真値はわからないものの、各パラメータについても旅行時間で負、アーケードや歩道幅員の変数に対して正の効果といったように、尤もらしい結果が得られている。U ターンダミーの変数が正の値をとっている結果については、他の交通手段に比較して歩行者にとっては U ターンへの抵抗が小さいことを表すと考えられるものの、より深い検証が必要である。さらに、観測モデルを通じてリンクの誤差分散  $\sigma_a$  を推定できる点も本モデルの特徴を示している (表-4)。これらの結果より、構造推定の有用性が示されたといえよう。

## 5. おわりに

経路や目的地といった空間選択行動を特定する、従前の確率的観測モデルはパラメータ設定にバイアスが含まれるという課題を残していた。本研究では経路選択行動に着目し、初期パラメータのバイアスが経路観測、そして経路選択モデルの推定結果にもバイアスを与えてしまうことに対して、観測モデルを内生化した経路選択モデルの推定手法を新しく提案した。また同時に、従前の経路観測モデルが抱えていた選択肢集合の課題に対して、リンクベースの経路観測手法を提案することで、課題の解決を試みた。

本論文ではまず、リンクベースの経路観測モデルを提案した。システム方程式がリンクベースの経路選択モデルとして記述できることによって、行動論的に意味のある経路を、候補集合を制限することなく観測できることを示した。また、状態を時間構造化処理し、リンクごとに観測方程式を評価することで、位置情報の誤差分散をリンク固有変数として扱うことが可能となった。また、逐次的な観測が引き起こし得る問題についても言及し、その対処方法としてリンクスイッチングアルゴリズムを提案した。

さらに、経路観測モデルと経路選択モデルが相互に依存関係を持つことに着目し、観測モデルを内生化した経路選択モデルの推定手法としての構造推定を提案した。双子実験によるモデルの検証では、リンクごとの誤差分散推定、スイッチングの導入により、経路の観測精度が向上することを確認した。一方でシステム方程式を導入する場合は観測精度が行動パラメータの

初期値に大きく依存することから、構造推定の必要性を明らかとした。構造推定の結果からは、パラメータの初期値に依らず一定の値に収束し、かつ真値での推定結果に近づく結果が求められることを明らかにした。実データを用いた検証もを行い、構造推定を用いることによってモデルの改善がなされたことも確認した。

サイクリック経路の観測や、 $\sigma$  の空間的分布とその統計的検証、経路ベースの観測モデルとの比較計算、双子実験の精緻化などが今後の課題である。

**謝辞：**本研究は JSPS 科研費 26-10824 の助成を受けたものです。ここに感謝の意を表します。

## 参考文献

- 1) Akamatsu, T., 1996. Cyclic flows, Markov process and stochastic traffic assignment. *Transportation Research Part B: Methodological* 30(5), pp.369-386.
- 2) Bell, M.G.H., 1995. Alternatives to Dial's logit assignment algorithm. *Transportation Research Part B: Methodological* 29(4), pp.287-295.
- 3) Ben-Akiva, M.E., Bierlaire, M., 1999. Discrete choice methods and their applications to short-term travel decisions. In: Hall, R. (Ed.), *Handbook of Transportation Science*. Kluwer, 5-34.
- 4) Bierlaire, M., Chen, J., Newman, J., 2013. A probabilistic map matching method for smartphone GPS data. *Transportation Research Part C: Emerging Technologies* 26, 78-98.
- 5) Bierlaire, M., Frejinger, E., 2008. Route choice modeling with network-free data. *Transportation Research Part C: Emerging Technologies* 16(2), 187-198.
- 6) Cascetta, E., Nuzzolo, A., Russo, F., Vitetta, A., 1996. A modified logit route choice model overcoming path overlapping problems. Specification and some calibration results for interurban networks. In: Lesort, J.B. (Ed.), *Proceedings of the 13th International Symposium on Transportation and Traffic Theory*, Lyon, France.
- 7) Chen, J., Bierlaire, M., 2015. Probabilistic multimodal map matching with rich smartphone data. *Journal of Intelligent Transportation System* 19(2), 134-148.
- 8) Danalet, A., Farooq, B., Bierlaire, M., 2014. A bayesian approach to detect pedestrian destination-sequences from WiFi signatures. *Transportation Research Part C: Emerging Technologies* 44, 146-170.
- 9) Fosgerau, M., Frejinger, E. and Karlstrom A., 2013. A link-based network route choice model with unrestricted choice set. *Transportation Research Part B: Methodological* 56, pp.70-80.
- 10) 布施孝志, 中西航, 2012. 歩行者挙動モデルを統合した人物追跡手法の構築. 土木学会論文集 D3 (土木計画学) 68(2), 92-104.
- 11) Hato, E., 2010. Development of behavioral context addressable loggers in the shell for travel-activity analysis. *Transportation Research Part C: Emerging Technologies* 18(1), 55-67.
- 12) Hato, E., Itsubo, S., Mitani, T., 2006. Development of MoALs (mobile activity loggers supported by gps-phones) for travel behavior analysis, TRB Annual Meeting in Washington DC.

- 13) Hunter, T., Abbeel, P., Bayen, A., 2014. The path inference filter: model-based low-latency map matching of probe vehicle data. *IEEE Transactions on Intelligent Transportation Systems* 15(2), 507-529.
  - 14) Mai, T., Fosgerau, M., Frejinger, E., 2015. A nested recursive logit model for route choice analysis. *Transportation Research Part B: Methodological* 75, pp.100-112.
  - 15) Oyama, Y., Chikamatsu, K., Shoji, Y., Hato, E., Koga, M., 2016. Trajectory-oriented traffic management using sequential discount rate: a case study of the Great East Japan Earthquake, the Proceedings of 11th ITS European Congress.
  - 16) 大山雄己, 羽藤英二, 2012. 街路景観の連続性を考慮した逐次的経路選択モデル, 都市計画論文集 47(3), 643-648.
  - 17) 大山雄己, 羽藤英二, 2016. 移動軌跡情報に基づく時間構造化ネットワーク上の交通配分, 土木計画学研究・講演集 53 (CD-ROM) .
  - 18) Pyo, J.S., Shin, D.H., Sung, T.K., 2001. Development of a map matching method using the multiple hypothesis technique. *IEEE Proceedings on Intelligent Transportation Systems*, 23-27.
  - 19) Rust, J., 1987. Optimal replacement of GMC bus engines: an empirical model of Harold Zurcher, *Econometrica*, Vol.55, No.5, pp.999-1033.
  - 20) van Diggelen, F., 2007. GNSS accuracy: lies, damn lies, and statistics. *GPS World* 18(1), 26-32.
- 

## A FIXED POINT PROBLEM OF ROUTE CHOICE MODEL UNDER MEASUREMENT UNCERTAINTY

Yuki OYAMA and Eiji HATO