

津波避難データの2つの回答バイアスに着目した動的活動経路選択モデルの推定手法

Estimation of Dynamic Activity Path Choice Model Correcting the Two Biases of Tsunami Evacuation Data

飯塚卓哉*, 羽藤 英二**
Takuya Iizuka*, Eiji HATO**

In a disaster management, methods for accurately predicting evacuation behavior are needed. We model a series of dynamic decision makings from the strikes of disasters to the completion of evacuations. Evacuation behavior data have difficulties in parameter estimation; 1) behavioral data from past disasters do not include responses of victims, 2) survey data for virtual disasters contain normalcy bias. In this paper, we model the evacuation behavior by an activity path choice model and propose a method to correct the bias contained in evacuation data in parameter estimation. This method allows to evaluate the staying time at the start or stopping point of evacuation routes. Numerical experiments and case studies showed the effectiveness of this method.

Keywords: Evacuation, Activity path choice, Parameter estimation, Bias correction
避難, 活動経路選択, パラメータ推定, バイアス補正

1 はじめに

2011年の東北地方太平洋沖地震により発生した大津波は、岩手県・宮城県・福島県を中心とした東日本沿岸地域に壊滅的な被害を与えた。津波到達までには最低30分以上の時間があったが、多くの人が避難を完了することができなかったことが課題として挙げられる。今後、南海トラフ巨大地震などによる被害が予測されている中で、適切な避難計画の立案は急務であろう。本研究の目的は、今後津波被害が予想される地域の避難計画立案に向けて、津波が来るまでの時間に行われる避難の意思決定を逐次的スケジュールリング問題としてその性質を明らかにし、正確な避難予測を行うことが可能なモデルを構築することである。

避難行動モデルについての研究は、避難開始時刻選択に関するもの¹⁷⁾、避難の目的地選択に関するもの¹³⁾など様々な蓄積がある。しかし、避難行動においては、津波(災害)がくるまでの時間における動的選択構造が重要であることが既往研究により指摘されている⁹⁾。意思決定者は現在地において被害を受けることが予想される場合に、将来リスクを想定した上で、被害を避けるために移動するか、その場に留まり避難以外の活動(情報収集、他者の避難支援等)をするかの選択を逐次的に行っていると考えることができよう。このような意思決定構造は動的活動経路選択モデルにより表現することができる。

避難行動モデルを推定する際には、主に過去の災害時に実際に行われた避難行動を記録したデータが用いられる。ここで注意すべきは、過去の災害時行動データは犠牲者のデータが含まれていないという点である。すなわち犠牲者の無回答バイアスを含んでいるという課題がある。特に津波の場合、避難開始が遅れた人や、低地部で避難以外の活動(情報収集、避難支援等)を行っていた人のデータが

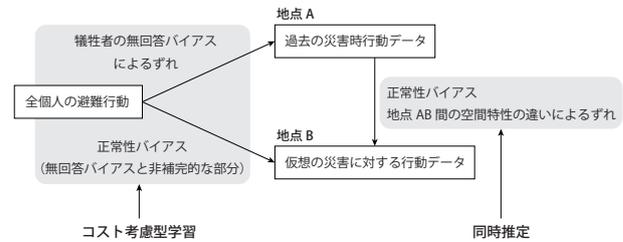


図1 本研究の提案する推定手法の概要

有意に欠損していることが懸念される。したがって過去の災害時行動データを用いて避難行動モデルを推定する場合、従来の推定手法では過度に安全な行動にパラメータが偏ってしまうことにつながり、避難行動予測において危険性を過小評価する恐れがある。また、過去に災害が起きていない地点については、仮定の災害を想定したアンケート調査などを行い、被験者の避難行動の意思表示を取得する必要がある。この場合、回答は正常性バイアスの影響を大きく受ける。例として、地震で家具が倒壊している状況や、テレビやラジオなどで情報収集する時間を過小評価して回答するため、現実よりも早期に避難を完了するといった回答が多くなる。この問題に対し、異なる地点における過去の災害時行動データをバイアス補正に利用することを試みる。これに似たケースを扱った研究として、交通分野ではRP/SP同時推定¹⁶⁾に関する研究の蓄積がある。

以上より本研究では、避難行動における動的選択構造を動的活動経路選択モデルにより定式化し、避難行動データの持つ種々のバイアスを補正してパラメータ推定を行う手法を提案する。図1に提案する推定手法の概念図を示す。具体的には、仮定の災害に対する行動データが持つ正常性

*学生会員 東京大学大学院 工学系研究科 (The University of Tokyo)

**正会員 東京大学大学院 工学系研究科 (The University of Tokyo)

バイアスとデータを取得した異なる2地点の空間特性の違いによるずれを過去の災害における実行データとの同時推定により除去する。また、過去の災害時行動データの持つ無回答バイアスと、仮定の災害に対する行動データの持つ正常性バイアスのうち同時推定では除去できない無回答バイアスと非補完的な部分を、コスト考慮型学習⁴⁾の考え方を新たに導入することで除去する。避難における一連の動的意識決定を一体的なモデルで記述し、避難行動データの種々のバイアスを除去する推定手法の導入により合理的な避難行動評価を可能にしている点が本研究の特徴である。

2 既往研究の整理

2.1 活動経路選択モデル

個人の移動と活動を一体的に記述するアクティビティモデルは、これまでに様々な理論が提案されてきている。平時の活動を記述するにあたっては、複数の活動の中での滞在時間を評価することが可能なため、歩行者回遊等への適用と発展が見られる。避難行動を記述する場合でも、避難開始前の準備や避難途中の自宅・親戚宅等への立ち寄りなどによって生じる滞在時間を避難遅れとして評価することが可能となる。活動経路選択モデルはアクティビティモデルの1つにあたり、種々の選択行動を時空間上の活動の軌跡として一体的に記述する手法である。従前の種々の選択行動を段階的に扱うモデル¹⁾と比べて、出発時刻や空間上の経路などの多次元を選択を一体的に記述できる利点がある。一方で、活動経路の選択肢が膨大になり、意思決定における経路選択肢集合を列挙することが困難になるという課題がある。

近年、この課題は経路非列挙型の経路選択モデルの適用によって解決が図られている。経路非列挙型の経路選択モデルは佐佐木(1965)¹⁴⁾、Dial(1971)²⁾を嚆矢として様々なモデルが提案されてきた。Fosgerau et al.(2013)⁵⁾はこれを動的離散選択モデル⁶⁾を用いて定式化し、従来の意思決定モデルとの整合性を持つRecursive Logit(RL)モデルを提案した。RLモデルは、経路選択行動を逐次リンク選択行動として捉え、次時点のリンクの選択効用に目的地までの期待効用を導入して定式化を行う。経路を選択されたリンクの系列として表現することで、あらかじめ目的地までの経路選択肢を列挙する必要性を回避している。Oyama and Hato(2017)⁷⁾は、RLモデルに割引率の概念を導入し、動的意識決定構造において将来価値を減じて考慮する行動原理を表現することを可能とした。

Oyama and Hato(2018)⁸⁾はRLモデルを時間構造化ネットワークに拡張し、滞り行動を明示的に考慮することによって時空間上の活動経路選択モデルとして定式化し、歩行者の回遊行動に適用している。これにより、従前のアクティビティモデルと比較して、高解像度の空間表現、選択肢集合列挙の回避を達成しつつ、逐次的に移動・滞りを選択するという意思決定の動学特性を表現している点に特徴がある。

2.2 同時推定手法

非集計行動モデルを推定する際のデータは大別して、実際の行動に基づくRPデータと、実験者により提示される仮定の状況における選好の意思表示であるSPデータが

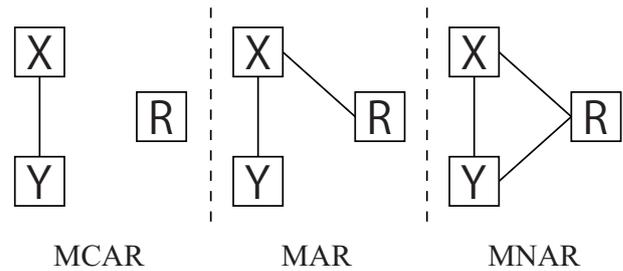


図2 欠損データの発生メカニズム概念図 (Yが欠損値のある変数, Xは変数Yの説明変数, Rは欠損値の有無を示す確率変数を表す)

ある。RPデータは実際の行動に基づいているため高い信頼性を有する反面、新しい交通機関や将来の災害などの現状にない状況下での回答結果は得られない。一方SPデータは一種の実験データであるため、仮定の状況下における選好を取り扱える反面、その回答は正常性バイアス、政策調整バイアスなど種々のバイアスの影響を受ける。森川・Ben-Akiva(1992)¹⁶⁾は、互いに補完的な性質を持つRP/SPデータを同時に用いて両データの長所を助長する同時推定手法を提案している。RPデータ、SPデータの発生過程をそれぞれランダム効用最大化理論に基づいて定式化し、効用関数にRPモデルとSPモデルで共通の項と、SPモデルに固有の項を設定することで、SPデータに特有のバイアスを除去することができる。需要予測に用いる効用関数においては、RPモデルとSPモデルで共通の項を利用することが考えられる。

2.3 欠損値の推定

Rubin(1976)¹¹⁾によると、欠損値はその発生のメカニズムからMissing Completely At Random(MCAR), Missing At Random(MAR), Missing Not At Random(MNAR)の3つのタイプに分けることができる。MCARは欠損値が完全にランダムに生じているようなケースである。MARは変数Yにおける欠損値の有無がY自体の値とは無関係だが、他の変数Xと関係しているケースである。MNARは変数Yにおける欠損値の有無が変数Xだけではなく、Y自体の値にも依存して決定しているケースである(図2)。避難行動データにおいては、欠損している犠牲者のデータはその避難行動そのものに強く依存しているため、MNARにあたりと考えられる。MCARやMARの場合は、完全情報最尤推定法や多重代入法によりバイアスを除去した推定を行うことができる。一方、MNARの場合は欠損データの発生メカニズムを正しくモデリングし、そのパラメータを求めることでバイアスを除去した推定を行うことができるが、現実的には欠損データの発生メカニズムをモデリングすることは困難であるため、必ずしも有効なバイアスの除去手法はない。

避難行動モデルを推定する場合、適切な避難計画を立案するためには、避難が失敗する可能性が高い行動の再現性を失わないようにしなければならない。すなわち、無回答バイアスや正常性バイアスの影響を受けたデータを用いる際に、低地部で避難以外の活動をするなどのリスクの高い行動を取る確率が不合理に低いモデルを推定してしまうこ

とが問題となる。これに似た状況において有効な学習手法として、Elkan(2001)⁴⁾ はコスト考慮型学習を提案している。あるクラスに属するデータを誤分類してしまうことのコスト(損失)に非対称性があるとき、非対称なコスト行列を設定し、期待コストを最小化することで誤分類コストの大きいクラスについての正答率を上げることができる。

2.4 本研究の位置づけ

本研究は、Oyama and Hato(2018)⁸⁾ の活動経路選択モデルをベースとして、災害が発生してから避難を完了するまでの避難行動をモデル化する。活動経路上の滞在時間は、情報収集などの避難準備や他者の避難支援行動による避難遅れとして評価することができる。次に、過去の災害時行動データと、仮定の災害に対する避難行動データのそれぞれが持つバイアスに対して、同時推定法とコスト考慮型学習の概念を導入することで、バイアスを除去してパラメータ推定を行う手法を提案する。本手法により、従前のモデルで課題とされてきた、避難行動の動的意識決定において重要な避難開始地点での滞在や避難途中の立ち寄りによる避難遅れを、バイアスの影響を除去して合理的に評価することが可能となる。

3 モデルのフレームワーク

3.1 活動経路選択モデルの定式化

本節では Oyama and Hato(2018)⁸⁾, Oyama and Hato(2017)⁷⁾ に基づいて避難における動的活動経路選択モデルを定式化する。旅行者は時空間ネットワーク $G=(S, A)$, $S=[S_0, \dots, S_t, \dots, S_T]$, $A=[A_0, \dots, A_t, \dots, A_T]$ 上を移動するものとする。 S_t は状態 $s_t = (t, l)$, ($l \in L$) を, A_t はアーク $a_t = (s_t, s_{t+1})$ をそれぞれ要素として持つ集合である。 T は時間制約を表す。 L は空間上の位置 l の集合とする。時空間ネットワーク上の活動経路 ψ は状態系列 $[s_0, \dots, s_t, \dots, s_T]$ として記述される。状態は時間と空間の組によって定義されるため、活動経路においてサイクリック経路を持ち得ない。一方で空間的サイクリック経路は排除せず、また同一位置における時間軸方向の遷移を滞在として扱うことができる。これにより、災害時の避難遅れや戻り避難などの行動を扱うことができる。

旅行者のアクティビティスケジューリング行動にマルコフ決定過程を仮定し、時空間ネットワーク上で逐次的に次時点の状態を選択するものとする。ある時点 t における状態 s_t から次時点の状態 s_{t+1} に遷移することを考える。旅行者は s_{t+1} への遷移に関する即時効用 $u(s_{t+1}|s_t)$ と、状態 s_{t+1} から目的地までに得られる期待効用 $V^{s_T}(s_{t+1})$ の和を最大化するように次時点の状態を選択すると仮定する。このとき、 $V^{s_T}(s_t)$ は Bellman 方程式¹⁰⁾ を用いた定式化が可能である。(以下では個人 n , 目的地 s_T の表記を省略する)

$$V(s_t) = \max_{s_{t+1} \in C(s_t)} E \left[\sum_{\tau=t}^T \gamma^{\tau-t} u(s_{\tau+1}|s_\tau) \right] \quad (1)$$

$$= E \left[\max_{s_{t+1} \in C(s_t)} \{v(s_{t+1}|s_t) + \gamma V(s_{t+1}) + \mu \varepsilon(s_{t+1})\} \right] \quad (2)$$

$v(s_{t+1}|s_t)$ は s_{t+1} への遷移に関する即時効用の確定項、 ε は i.i.d. ガンベル分布に従う即時効用の確率項、 μ はスケールパラメータ、 γ は割引率である。 $C(s_t)$ は状態 s_t から接続する次時点の状態集合を表す。このとき、状態 s_t から状態 s_{t+1} に遷移する確率は以下のように Logit モデルの形式で表される。

$$p(s_{t+1}|s_t) = \frac{e^{\frac{1}{\mu}(v(s_{t+1}|s_t) + \gamma V(s_{t+1}))}}{\sum_{s'_{t+1} \in C(s_t)} e^{\frac{1}{\mu}(v(s'_{t+1}|s_t) + \gamma V(s'_{t+1}))}} \quad (3)$$

状態系列である活動経路 $\psi = [s_1, \dots, s_t, \dots, s_T]$ の選択確率は、状態遷移確率の積として表される。

$$\Pr(\psi) = \prod_{t=0}^{T-1} p(s_{t+1}|s_t) \quad (4)$$

確率項 ε にガンベル分布を仮定しているため、式(2)は以下のように、ログサム形式で表すことができる。

$$V(s_t) = \begin{cases} \mu \log \sum_{s_{t+1} \in C(s_t)} \delta_{s_t}^{s_{t+1}} e^{\frac{1}{\mu}(v(s_{t+1}|s_t) + \gamma V(s_{t+1}))}, & s_t \neq s_T \\ 0, & s_t = s_T \end{cases} \quad (5)$$

$\delta_{s_t}^{s_{t+1}}$ は $s_{t+1} \in C(s_t)$ のときに1、それ以外で0となる指示変数である。目的地から先に続く状態はないため、 $V(s_T) = 0$ とする。時空間ネットワークでは活動経路のサイクリック構造が除去されているため、式(5)を繰り返し用いることで、単純な後ろ向き帰納法により期待効用 $V(s_t)$ を算出することが可能である。

3.2 推定手法

前節で定式化した動的活動経路選択モデルのパラメータは最尤法によって推定される。即時効用が $v(s_{t+1}|s_t) = \beta \mathbf{x}(s_{t+1}|s_t)$ のようにパラメータと説明変数の線形和で表されるとき、対数尤度関数 LL は以下のように定義される。

$$LL(\beta, \gamma) = \ln \prod_{n=1}^N \Pr_n(\psi_n = [s_1, \dots, s_T]) \quad (6)$$

$$= \sum_{n=1}^N \sum_{t=0}^{T-1} \ln p_n(s_{t+1}|s_t) \quad (7)$$

$$= \sum_{n=1}^N \sum_{t=0}^{T-1} \frac{1}{\mu} (v_n(s_{t+1}|s_t) + \gamma V_n^{s_T}(s_{t+1}) - V_n^{s_T}(s_t)) \quad (8)$$

しかし前述の通り、過去の災害時行動データ、仮定の災害に対する行動データを用いて推定を行う場合、種々のバイアスによりパラメータ推定値が歪んでしまうことが考えられる。本節では、森川・Ben-Akiva(1992)¹⁶⁾ の同時推定手法と、Elkan(2001)⁴⁾ のコスト考慮型学習の考え方を組み合わせることで、動的離散選択モデルの推定におい

て避難時の調査回答バイアスを除去したパラメータ推定を行う手法を提案する。

以下では、過去の災害時行動データを取得した地点をA、仮定の災害に対する避難行動調査により行動データを取得した地点をBとし、それぞれのデータをAデータ、Bデータと呼ぶ。Aデータを生成するAモデルとBデータを生成するBモデルを考える。AモデルとBモデルの間で主要な真のパラメータ間のトレードオフ関係は共通と考える。それぞれのモデルにおける即時効用は以下のように定式化される⁽¹⁾。

A model

$$u_n^A(s_{t+1}|s_t) = \beta \mathbf{x}_n^A(s_{t+1}|s_t) + \varepsilon_n^A(s_{t+1}) \\ = v_n^A(s_{t+1}|s_t) + \varepsilon_n^A(s_{t+1}) \quad (9)$$

$$\delta_n^A(s_{t+1}) = \begin{cases} 1: \text{個人 } n \text{ が状態 } s_{t+1} \text{ に遷移した場合} \\ 0: \text{otherwise} \end{cases}$$

B model

$$u_n^B(s_{t+1}|s_t) = \beta \mathbf{x}_n^B(s_{t+1}|s_t) + \alpha \mathbf{w}_n^B(s_{t+1}|s_t) + \varepsilon_n^B(s_{t+1}) \\ = v_n^B(s_{t+1}|s_t) + \varepsilon_n^B(s_{t+1}) \quad (10)$$

$$\delta_n^B(s_{t+1}) = \begin{cases} 1: \text{個人 } n \text{ が状態 } s_{t+1} \text{ に遷移した場合} \\ 0: \text{otherwise} \end{cases}$$

\mathbf{x} はA/Bモデルで共通のパラメータ β を持つ説明変数ベクトル、 \mathbf{w} はBモデルに固有のパラメータ α を持つ説明変数ベクトルである。本研究では、BデータがAデータに対して持つ相対的なバイアスを同時推定により除去することを想定する。つまり、 α はBデータがAデータに対して持つ相対的バイアスを表しており、これによってBデータ特有の仮定の災害を想定することに起因する正常性バイアスなどを一部除去することができる。

A/Bデータのそれぞれを用いて式(9)、(10)のパラメータを別々に推定すると、それぞれの誤差項の分散の大きさに従った推定値が得られる。そこで、推定の際にパラメータを両モデルで共有するためにスケールパラメータを導入する。スケールパラメータ ν はそれぞれのモデルの誤差項の分散の比で与える。 ν の推定値が1よりも小さければ、BモデルではAモデルよりも誤差項が卓越していることになる。

$$\text{Var}(\varepsilon_{in}^A) = \nu^2 \text{Var}(\varepsilon_{in}^B) \quad (11)$$

上記手法により、BデータのAデータに対する相対的バイアスのみが除去される。しかし前述の通り避難行動のデータは過去の災害の記録であるAデータにおいても、犠牲者の行動データが得られていないために無回答バイアスを含んでいる。また、Bデータの正常性バイアスはAデータの無回答バイアスと非補完的であることが想定されるため、同時推定ではバイアスの除去は不十分である。避難計画の立案においては、被災する可能性の高い行動を正確に評価し、適切な規模の計画を行うことが重要となる。そのため、犠牲者の避難行動や仮定の災害を想定した調査で得られづらい回答に多く見られると思われるような、避

難開始の遅れや、低地部における避難以外の活動などを見逃すコストが特に大きい。こうした見逃しコストや誤分類コストが非対称的な状況における学習法として、コスト考慮型学習⁴⁾が提案されている。特にコスト考慮型学習を最尤法において達成するには、サンプルの見逃しコスト(誤分類コスト)の大きさに伴って対数尤度関数を重みづけする手法が有効である¹²⁾³⁾。本研究においては、避難行動データにおける状態遷移の危険度(リスク)を考え、リスクの大きい遷移ほど見逃しコストが大きいものとして重み付き対数尤度関数を定式化する。状態 s_{t+1} に遷移することのリスクを $c(s_{t+1})$ で表し、対数尤度関数の重みとして用いる。このときのAモデル、Bモデルの重み付き対数尤度関数は以下の式で定義される。ただし、Aモデルのスケールパラメータ $\mu = 1$ とし、A/Bモデルのサンプル数をそれぞれ N^A, N^B とする。

A model

$$LL^A(\beta, \gamma) = \sum_{n=1}^{N^A} \sum_{t=0}^{T^A-1} c(s_{t+1}) \ln p_n(s_{t+1}|s_t) \quad (12)$$

$$= \sum_{n=1}^{N^A} \sum_{t=0}^{T^A-1} c(s_{t+1})(v_n(s_{t+1}|s_t) + \gamma V_n^{sT}(s_{t+1}) - V_n^{sT}(s_t)) \quad (13)$$

B model

$$LL^B(\beta, \alpha, \gamma, \nu) = \sum_{n=1}^{N^B} \sum_{t=0}^{T^B-1} c(s_{t+1}) \ln p_n(s_{t+1}|s_t) \quad (14)$$

$$= \sum_{n=1}^{N^B} \sum_{t=0}^{T^B-1} \nu c(s_{t+1})(v_n(s_{t+1}|s_t) + \gamma V_n^{sT}(s_{t+1}) - V_n^{sT}(s_t)) \quad (15)$$

A/B同時推定モデルの重み付き対数尤度関数は、Aモデルの対数尤度関数(式(13))とBモデルの対数尤度関数(式(15))の和で与えられる。

$$L^{A+B}(\alpha, \beta, \gamma, \nu) = L^A(\beta, \gamma) + L^B(\alpha, \beta, \gamma, \nu) \quad (16)$$

式(16)を最大化することで、BモデルのAモデルに対する相対的バイアス、Aモデルの持つ無回答バイアスの双方が除去されたパラメータ推定値が得られる。今回は重み $c(s_{t+1})$ は以下の単純な式で与える。

$$c(s_{t+1}) = 1 + a \frac{d^{sT}(s_{t+1})}{\tau_t}, t \neq T \quad (17)$$

$d^{sT}(s_{t+1})$ は状態 s_{t+1} から目的地 s_T への空間的直線距離、 τ_t は時点 t から時間制約 T (津波到達時刻など)までの残りステップ数 $T-t$ とする。 a は正の定数である。目的地(避難所など)への距離が長いほど、また残り時間が短いほど重み $c(s_{t+1})$ は大きい。つまり遷移先の状態 s_{t+1} のリスクの大きさに応じて対数尤度関数内における重みも大きくなる。

4 数値実験

本章では、前章で提案した推定手法の有効性を数値実験により確認する。以下では、Aモデルのスケールパラメータ $\mu = 1$ 、割引率 $\gamma = 0.75$ 、式(17)における定数 $a = 1$ と固定する。

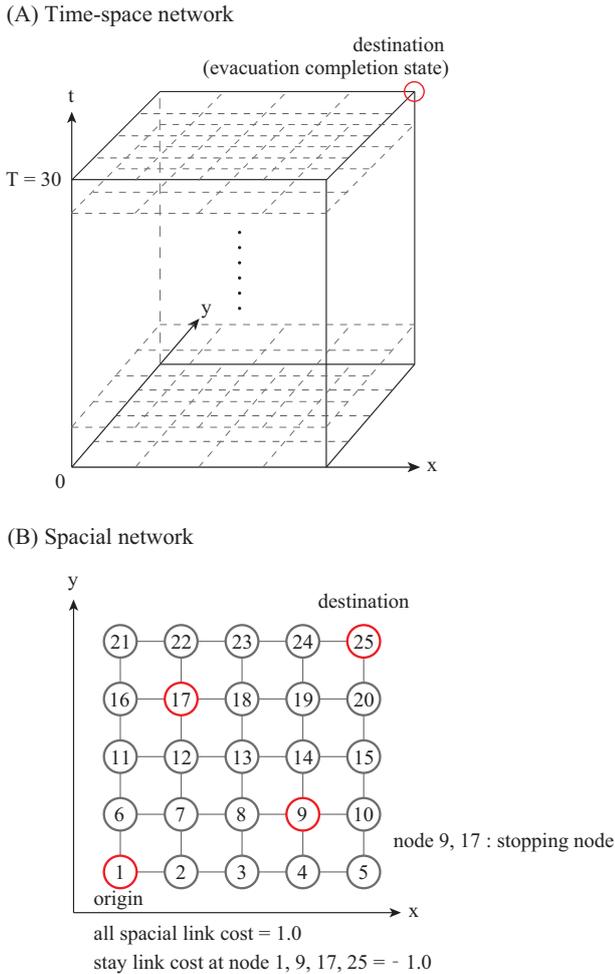


図3 数値実験で用いた仮想ネットワーク

4.1 計算設定

図3に数値実験で用いる仮想ネットワークを示す。空間ネットワークは5×5のグリッド型のネットワークで、時間制約 $T = 30$ とする。すべての移動リンクコストを1に設定し、出発ノード1、中継地ノード9・17、目的地ノード25における1ステップの滞在リンクコストを-1（滞在効用を+1）とする。出発地ノードから避難を開始し、避難途中の中継地における活動（避難支援等）を経て目的地（避難所等）に到着する避難行動を表している。

このネットワーク上で式(3)を繰り返し用いて30ステップのマルコフ配分を行い活動経路データを生成し、従来の推定手法と提案手法によるパラメータ推定結果を比較する。配分時はBモデルのスケールパラメータは1に設定した。A/Bモデルそれぞれで表1のようにパラメータの真値を仮定しAモデルで1000サンプル、Bモデルで200サンプル活動経路を生成する。Origin node stay dummy と family node stay dummy のパラメータ値のA/Bモデル間の差はBデータに含まれるバイアスを表す。Aモデルから生成されたサンプルの内30ステップの遷移終了時点で目的地ノードに到着しているサンプルのうち300サンプルをランダムサンプリングして推定に使用する。これにより、Aデータにおける犠牲者の無回答バ

イアスを表現する。Bデータから生成された200サンプルは全て推定に使用する。ここでの目的は、200サンプルのBデータと300サンプルの抽出されたAデータから、Aモデルのパラメータ真値を推定することである。

4.2 推定結果

表2に各手法における推定結果を示す。それぞれ(1)Bデータのみで通常の最尤法を行った結果、(2)Aデータのみで通常の最尤法を行った結果、(3)A/Bデータで同時推定を行った結果、(4)A/Bデータで式(17)の重みを用いた重み付き同時推定を行った結果である。今回推定された値はすべて1%有意な値であった。

Bデータから推定されたパラメータはBモデルの真値に近い値を示した。Aデータから推定されたパラメータは真値に比べて目的地ノード滞在ダミーが高く、他のパラメータは小さく推定されている。これは30ステップの遷移終了時点で目的地ノードに到着した300サンプルのみを用いて推定したことによるバイアスの影響が表れている。このようにAデータ、BデータのそれぞれがAモデルのパラメータ真値とのずれを含んでいる場合の、従来の同時推定法と提案手法の効果を各パラメータ推定値とAモデルのパラメータ真値との間の二乗平均平方根誤差(RMSE)によって比較した。従来の同時推定法におけるRMSEは0.329であり、Aデータのみ、Bデータの場合に比べて推定値の誤差の改善が見られた。提案手法におけるRMSEは0.269であり、従来手法に比べてさらに誤差の改善が見られた。出発地滞在ダミーと目的地滞在ダミーのパラメータ推定値が真値に近づいており、Aデータに含まれる無回答バイアスの影響が一部除去されていると考えられる。

5 ケーススタディ

3章で提案した動的活動経路選択モデルの推定法を用いて、実データにおけるパラメータ推定を行い推定結果を考察する。

5.1 データ概要と計算の設定

仮想の災害を想定した避難行動調査データとして、2019年に愛媛県宇和海沿岸市町に対して行われた南海トラフ巨大地震対策にむけた避難意向調査のうち、愛媛県愛南町家串地域で得られた結果を使用する。過去の災害における実行動データとしては、国土交通省都市局の「東日本大震災津波被災市街地復興支援調査」の調査結果のうち、岩手県陸前高田市のデータを使用する。本調査は東北地方太平洋沖地震発生後に被災市町村の復興計画づくりを支援することを目的として行われたものである。そのため、東日本大震災における犠牲者の回答は得られていないと考えられる。各データの概要を表3に示す。愛南町家串で行った調査は、南海トラフ巨大地震が発生する日時を仮定した場合に津波から逃げる際の出発地点から目的地（避難場所）までの一連のトリップについて、出発時刻・到着時刻、場所、活動の内容、経路などについて紙面の地図上に回答してもらう形式の調査である。陸前高田市で行われた調査データは、復興支援調査アーカイブ¹⁵⁾として公開されており、地震発生時からの一連のトリップについて同様の内容が記録されている。なお、回答が得られている全モニ

表1 活動経路データ生成に用いたパラメータ真値

	Explanatory variables			
	link cost	origin node stay dummy	stopping node stay dummy	destination node stay dummy
A model	-0.5	1.0	1.0	3.0
B model	-0.5	0.5	0.5	3.0

表2 各データにおける推定結果

explanation variables	(1)B data		(2)A data		(3)A+B data		(4)weighted A+B data	
	parameter	t-value	parameter	t-value	parameter	t-value	parameter	t-value
link cost	-0.487	-12.7	-0.470	-12.4	-0.509	-17.2	-0.521	-20.4
origin node stay dummy	0.503	10.1	0.840	21.5	0.810	23.5	0.811	27.0
stopping node stay dummy	0.451	6.14	0.932	18.3	0.905	18.9	0.874	20.5
destination node stay dummy	3.07	40.6	3.65	54.3	3.62	54.8	3.49	58.2
origin node stay dummy(B 固有)	-	-	-	-	-0.183	-3.01	-0.150	-2.80
stopping node stay dummy(B 固有)	-	-	-	-	-0.344	-3.74	-0.311	-4.04
scale parameter ν	-	-	-	-	0.859	35.2	0.856	37.7
Num of Samples		200		300		500		500
initial likelihood		-8423.5		-12495.6		-20919.2		-25761.0
final likelihood		-5827.1		-7060.0		-12888.6		-17375.9
likelihood ratio		0.308		0.435		0.384		0.325
RMSE	0.372		0.335		0.329		0.269	

表3 避難データ概要

	愛南町家串	陸前高田市
調査期間	2019年8月24日~9月8日	2011年度
調査対象	愛媛県愛南町家串地区の居住者	岩手県陸前高田市での被災者
モニター数	112名	510名
有効モニター数	45名	300名

ターのうち、出発時刻・到着時刻、場所、経路についての記述に不備の無いモニターを有効モニターとして抽出した。

図4、図5は家串、陸前高田それぞれの空間ネットワーク図である。家串は道路交差点にノードを置き、ノード間をリンクでつないだ通常のネットワークである。陸前高田は交差点数が非常に多く、家串と同様のネットワークでは計算量が膨大になってしまい、現実的な時間内に最尤推定を行うことができない。そのため、500mメッシュ内に含まれる交差点の重心を代表点として空間ノードとし、これをリンクでつなぐことでネットワークを構成した。滞在方向のリンクについても、陸前高田の時空間ネットワークサイズを抑えるため、家串で1分、陸前高田で5分を一単位とする。活動経路選択モデル内で1ステップごとに期待効用が割引率 γ で割引かれる定式化を行っているため、本来は空間リンク・滞在リンクがある単位時間で統一されたネットワークを用いることで、時間に対して一定の割引率を考慮することができる。ネットワークサイズが大きい場合の活動経路選択モデルの推定法については今後の課題である。時間制約 T はそれぞれの地域で得られたデータの中で、空間リンク遷移数と滞在ステップ数の合計が最も大きいモニターの値に統一し、家串で $T = 45$ 、陸前高田で $T = 25$ とした。これよりも短いステップ数で避難場所に到着したモニターについては、避難

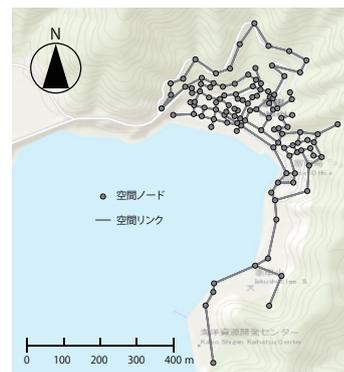


図4 家串ネットワーク

場所到着後、ステップ数が T となるまで避難場所で滞在していたものと見なした。

式(9)、(10)における即時効用 $v(s_{t+1}|s_t)$ について、陸前高田と家串に共通の説明変数 \mathbf{x} には、遷移における空間的リンク長(m)、遷移前後のノードの標高差(m)、出発地ノード滞在ダミー、中継地ノード滞在ダミー、目的地ノード滞在ダミーを用いた。ただし変数のスケールを統一するため、陸前高田のリンク長を100で、陸前高田の標高差と家串のリンク長・標高差を10でそれぞれ除し

表4 実データにおける推定結果

explanation variables	(1) 家串		(2) 陸前高田		(3) 家串 + 陸前高田				
	parameter	t-value	parameter	t-value	parameter	t-value			
link length(陸前高田/100m, 家串/10m)	0.030	0.919	-0.120	-7.88	**	-0.012	-1.39		
elevation difference(/10m)	-0.254	-0.653	0.005	0.204		0.004	0.266		
origin node stay dummy	1.77	17.4	**	1.38	16.7	**	1.73	30.3	**
stopping node stay dummy	0.391	2.31	*	0.550	11.4	**	0.766	19.7	**
destination node stay dummy	3.08	18.1	**	3.29	19.3	**	3.47	51.2	**
origin node stay dummy(家串固有)	-	-	-	-	-	-0.693	-6.64	**	
stopping node stay dummy(家串固有)	-	-	-	-	-	-0.396	-2.18	*	
scale parameter ν	-	-	-	-	-	1.99	11.8	**	
discount rate γ	0.927	77.4	**	0.466	14.6	**	(固定)0.466		
Num of Samples		45		300			345		
initial likelihood		-2824.3		-11994.7			-16315.8		
final likelihood		-471.0		-2504.7			-4554.1		
likelihood ratio		0.831		0.791			0.720		

* 5% 有意

** 1% 有意

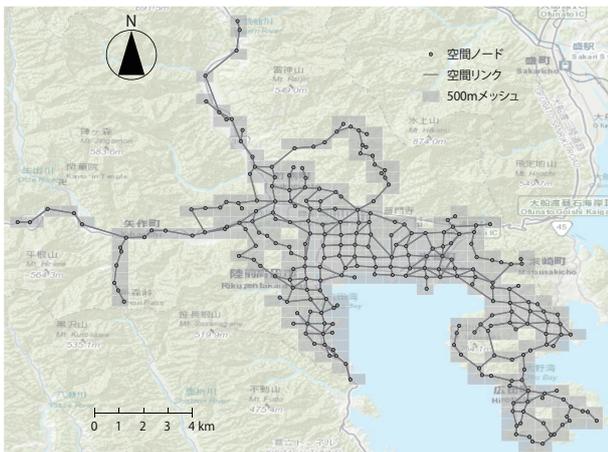


図5 陸前高田ネットワーク

ている。仮定の災害を想定することに起因するバイアスは、特に出発地ノード滞在ダミーと中継地ノード滞在ダミーのパラメータに含まれていることを仮定し、この二つを家串に固有の説明変数 w として設定した。式 (17) の重みにおける定数 a は、重みの値を両データで近い値とするために陸前高田データで $a = 0.01$ 、家串データで $a = 0.1$ とする。

5.2 推定結果

以下では、陸前高田モデルのスケールパラメーター $\mu = 1$ に固定する。本章では割引率 γ も最尤法により推定する。パラメータ推定結果を表4に示す。(1), (2) は家串, 陸前高田のデータそれぞれを用いて通常の最尤法を行った結果である。両データにおいて出発地ノード滞在ダミー, 中継地ノード滞在ダミー, 目的地ノード滞在ダミーは正に有意な値を, 陸前高田データでリンク長が負に有意な値を示した。これらは直観に合う結果となっている。割引率も有意に推定されており, 家串で 0.927, 陸前高田で 0.466 を示している。家串の方が 1 に近い値が推定されており, 家串では将来の期待効用を重視して考える

プレトリップ型の回答が得られていることを示している。一方で、陸前高田では将来の期待効用に比べて直近の即時効用が重視されていることを示している。実際の避難行動では直近の活動を優先してしまう近視眼的な行動が行われているが、家串で行われた仮定の災害を想定した調査では家具が倒れている状況や、避難開始前の情報収集の時間を想定せず、津波到達時刻より前に避難を完了するように早めに避難所に向かうというような回答をするという正常性バイアスの影響が表れていると言えよう。(3) は両データを用いて3章で提案した重み付き同時推定法を行った結果である。(3) の推定では、実際の被災地における値が現実に即していると考え、割引率 γ を陸前高田データでの推定値に固定している。家串固有の出発地ノード滞在ダミーと中継地ノード滞在ダミーは負で有意に推定されており、家串データにおける回答では、出発地や中継地における避難以外の活動による滞在時間が短く見積もられていることを示している。この点から、同時推定により家串データに固有の正常性バイアスが一部除去されていると言える。スケールパラメーター ν の推定値は 1.99 であり、陸前高田データの方が誤差項が卓越しているという結果となった。これは仮定の災害に対して紙面上で避難行動を回答するよりも、実際の災害では多様な活動パターンが見られることに起因すると考えられる。

表5に家串データにおいて、補正前後のパラメータ推定値を用いて避難シミュレーションを行った場合の、避難完了ステップの比較を示す。避難シミュレーションは、式(3)を繰り返し用いることで行った。バイアス補正した推定結果を用いることで、避難完了サンプル数は減少し、避難完了ステップ数は平均値、最遅値ともに増加した。家串での調査で考慮されていなかった避難の出発地や中継地における滞在行動による避難遅れが再現できていると言える。

6 結論と今後の展望

本研究では避難行動における動的選択構造を動的活動経路選択モデルにより定式化し、避難行動データの取得方

表5 家串データ (サンプル数 45, 時間制約 $T = 45$) における避難シミュレーションでの避難完了ステップの比較

	補正前 (表 4(1) 推定値)	補正後 (表 4(3) 推定値)
避難完了サンプル数	34	14
避難完了ステップ (平均)	8.71	17.5
避難完了ステップ (最遅)	29	42

法に起因する種々のバイアスを除去してパラメータ推定を行う手法を提案した。動的活動選択モデルを用いることで、特に津波のような限られた時間内の逐次的なスケジュールリング問題として、出発時刻や、中継地での避難以外の活動による滞在時間、避難経路という選択要素を一体的に記述することを可能にしたことは成果といえよう。次に、現実の避難計画において、行われている仮定の災害を想定した避難行動を回答する SP 調査と、過去の同種の災害における行動記録のそれぞれについて含まれるバイアスの性質に着目し、交通分野で蓄積のある RP/SP 同時推定と、コスト考慮型学習の考え方を組み合わせた重み付き同時推定により、バイアスを除去したパラメータ推定が可能であることを数値実験により示した。津波によって回答結果が得られない亡くなった方々の行動記録が残されていないことによるバイアスが補正できる可能性を示した。最後に実データを用いた推定により、仮想災害を想定した調査データに含まれる正常性バイアスの影響が割引率の値により確認できること、およびその影響を融合推定法により除去できることを示した。

実際には、現実の災害状況下で犠牲者も含めた全体の避難行動データを取得することはできないため、実データにおいて重み付き最尤法による無回答バイアス補正の効果を確認することは困難である。本稿では重み付き最尤法において式 (17) のような、遷移先の状態における目的地までの距離と時間制約下の残り時間から与えられる単純な重みの値を用いた。しかしこの値は定数 a の値の与え方や、データを取得した地域の地理条件によって変化する値である。特に今回のようにスケールの異なる 2 地域のデータを用いる際に、スケールの大きい地域のデータの重みが極端に大きくなってしまいうため、 a の値を調整する必要がある。本来、データの条件に関わらず数理的に一貫性のある定式化をされた重みを用いることが望ましい。例えば遷移先の状態のリスク指標として、遷移先の状態からモンテカルロ木探索を複数回行い、終端時刻において避難を成功/失敗したかの確率値を用いるという手法が考えられる。こういった手法への発展については今後の課題である。また、割引率についても仮想災害データの正常性バイアスの影響が表れている可能性が大きいため、同時推定において固有パラメータを設定すべきだと考えられる。しかし割引率は効用確定項の外にあるパラメータであるため、従来の同時推定法では片方のデータに固有な部分を設定して推定することができない。同時推定法の発展についても今後の課題である。

【補注】

(1) 森川・Ben-Akiva(1992)¹⁶⁾ では RP/SP データは同一地点で取得されたことを前提としているが、本稿では異なる地点で得られたデータへの同時推定の適用を想定している。

【参考文献】

- [1] J. L. Bowman and M. E. Ben-Akiva. Activity-based disaggregate travel demand model system with activity schedules. *Transportation Research Part A: Policy and Practice*, 35(1):1-28, 2001.
- [2] R B Dial. A probabilistic multipath traffic assignment algorithm which obviates pathenumeration. *Transportation Research*, 5(2):83-111, 1971.
- [3] Jacek P. Dmochowski, Paul Sajda, and Lucas C. Parra. Maximum likelihood in cost-sensitive learning: Model specification, approximations, and upper bounds. *Journal of Machine Learning Research*, 11:3313-3332, 2010.
- [4] Charles Elkan. The foundations of cost-sensitive learning. *IJCAI International Joint Conference on Artificial Intelligence*, pages 973-978, 2001.
- [5] Mogens Fosgerau, Emma Frejinger, and Anders Karlstrom. A link based network route choice model with unrestricted choice set. *Transportation Research Part B: Methodological*, 56:70-80, 2013.
- [6] John Rust. Optimal Replacement of GMC Bus Engines : An Empirical Model of Harold Zurcher. *Econometrica*, 55(5):999-1033, 1987.
- [7] Yuki Oyama and Eiji Hato. A discounted recursive logit model for dynamic gridlock network analysis. *Transportation Research Part C: Emerging Technologies*, 85(September):509-527, 2017.
- [8] Yuki Oyama and Eiji Hato. Link-based measurement model to estimate route choice parameters in urban pedestrian networks. *Transportation Research Part C: Emerging Technologies*, 93(May):62-78, 2018.
- [9] Adam J Pel, Michiel C J Bliemer, and Serge P Hoogenboom. A review on travel behaviour modelling in dynamic traffic simulation models for evacuations. *Transportation*, 39(1):97-123, 2012.
- [10] Bellman R. Dynamic Programming. *Princeton University Press*, 1957.
- [11] Donald B. Rubin. Biometrika Trust Inference and Missing Data. *Biometrika*, 63(3):581-592, 1976.
- [12] Hidetoshi Shimodaira. Improving predictive inference under covariate shift by weighting the log-likelihood function. *Journal of Statistical Planning and Inference*, 90(2):227-244, 2000.
- [13] Giancarlo Troncoso Parady and Eiji Hato. Accounting for spatial correlation in tsunami evacuation destination choice: a case study of the Great East Japan Earthquake. *Natural Hazards*, 84(2):797-807, 2016.
- [14] 佐佐木綱. 吸収マルコフ過程による交通量配分理論. *土木学会論文集*, (121):28-32, 1965.
- [15] 東京大学空間情報科学研究センター 国土交通省都市局. 復興支援調査アーカイブ, 2012. <http://fukkou.csis.u-tokyo.ac.jp/>.
- [16] M. Ben-Akiva 森川高行. RP データと SP データを同時に用いた非集計行動モデルの推定法. *交通工学*, 27(13):21-30, 1992.
- [17] 柳沼秀樹 浦田淳司, 羽藤英二. 将来効用の動学的異質性を考慮した避難開始選択モデルの構築. *土木計画学論文集 D3(土木計画学)*, 72(4):261-277, 2016.