

2022.5.23

理論談話会 #9

10:00-11:00 @セミナーB

# A decomposition method for estimating recursive logit based route choice models

---

Mai, Tien, Fabian Bastin, and Emma Frejinger.

EURO Journal on Transportation and Logistics 7.3 (2018): 253-275.

M1 増橋 佳菜

# 0. Abstract

## 経路選択モデルの課題

課題0 経路の選択肢集合が不明

課題1 経路同士の相関

解決策0

再帰的な定式化 (マルコフ連鎖による記述)  
→ 選択肢集合を列挙しない

## Recursive Logit Model (Fosgerau; 2013)

課題1 経路同士の相関を考慮できない (LS 以外にIIA特性が残る) ※不十分!!!

課題2 多数の大規模な連立方程式を解く必要性 → 計算時間コストが高い  
→ 大規模NW・複雑なモデルに適用困難

課題1 → 解決策1

複雑なモデル

Mixed RLモデルの採用 → IIA特性が緩和

理論的に可能

課題2 → 解決策2

Decomposition method (DeC method)を提案 → 超高速化

(RLモデルで実証)


+α Mixed RL モデルへの適用

実際に可能

# 2. Recursive Logit Model

- ネットワークの定義

- $G = (A, \nu)$ : 有向リンクで結ばれたネットワーク
- $A$ : リンク集合、 $\nu$ : ノードの集合



- 効用関数

- 即時効用  $u_n(a|k) = v_n(a|k) + \mu \varepsilon_n(a)$
- 期待効用  $V_n^d(a)$

- 価値関数  $V_n^d(k)$  - Bellman方程式の形

- $V_n^d(k; \beta) = E \left[ \max_{a \in A(k)} (v_n(a|k; \beta) + V_n^d(a; \beta) + \mu \varepsilon_n(a; \beta)) \right] \quad \forall k \in A$

※ 以下、個人 $n$ の表記を省略

- 選択確率  $P^d(a|k)$

$$P^d(a|k) = \frac{\delta(a|k) \exp\left(\frac{1}{\mu} (v(a|k) + V^d(a))\right)}{\sum_{a' \in A(k)} \exp\left(\frac{1}{\mu} (v(a'|k) + V^d(a'))\right)}$$

接続行列

※ 導出過程は参考資料 [6]pp.16参照

全ての可能な経路に対して各ノードでMNL型の選択を行う

# 2. Recursive Logit Model

## IIA特性 (Independence from Irrelevant Alternatives)

2つの選択肢を考えると「その2つの選択肢の確定項のみの影響を受け、  
 選択肢集合に含まれる他の選択肢の影響を受けない」性質。  
 無関係な選択肢からの選択確率の独立性を保証している。

- 経路  $\sigma = \{k_i\}_{i=0}^I = \{k_0, k_1, \dots, k_I\}$  について  
発生                  吸収  
= d
- 経路  $\sigma$  の選択確率 = 経路  $\sigma$  が観測されたときの尤度  $P(\sigma)$

$$\begin{aligned}
 P(\sigma) &= \prod_{i=0}^{I-1} P(k_{i+1}|k_i) \\
 &= \prod_{i=0}^{I-1} \frac{\exp\left(\frac{1}{\mu} (v(k_{i+1}|k_i) + V^d(k_{i+1}))\right)}{\sum_{a \in A(k_i)} \exp\left(\frac{1}{\mu} (v(a|k_i) + V^d(a))\right)} = e^{\frac{1}{\mu} v^d(k)} \\
 &= \prod_{i=0}^{I-1} \exp\left(\frac{1}{\mu} (v(k_{i+1}|k_i) + V^d(k_{i+1}) - V^d(k_i))\right) \\
 &= \exp\left(-\frac{1}{\mu} V^d(k_0)\right) \prod_{i=0}^{I-1} \exp\left(\frac{1}{\mu} v(k_{i+1}|k_i)\right) \quad (\because V^d(k_i) = 0) \\
 &= \frac{\exp\left(\frac{1}{\mu} v(\sigma)\right)}{\exp\left(\frac{1}{\mu} V^d(k_0)\right)} = \frac{\exp\left(\frac{1}{\mu} v(\sigma)\right)}{\sum_{\sigma' \in \Omega} \exp\left(\frac{1}{\mu} v(\sigma')\right)}
 \end{aligned}$$

経路  $\sigma$  の確定項

(  $\Omega$  : 全経路の集合 )      可能な経路の確定項和

RLモデルは  
 “無限の選択肢を持つMNLモデル”  
 → IIA特性を持つ  
 経路  $\sigma_1$  と経路  $\sigma_2$  の確率の比は  
 $v(\sigma_1) - v(\sigma_2)$  のみに依存

**課題 1** 経路同士の相関を考慮できない

# 番外編 LS (リンクサイズ属性) とIIA特性の緩和

## ● リンクの重複 → **課題 1** 経路同士の相関

### ● 既往研究

- 共通性係数 (c-logitモデル) (Cascetta et al.;1996)
- PS属性 (PSLモデル) (Ben-Akiva and Bierlaire; 1999)

・与えられた経路 $j$ ,  $j$ のリンク集合 $\Gamma_j$ , 選択肢集合 $C$ , リンク $a$ の長さ $L_a$ に対して

$$PS_{jn} = \sum_{a \in \Gamma_j} \frac{L_a}{L_j} \frac{1}{\sum_{i \in C_n} \delta_{ai}} \leftarrow \text{リンク } a \text{ を通る経路数}$$

- ・経路 $j$ がどのリンクとも重複していないと1に、重複度大で0に近づく
- ・経路の効用の補正は $\beta_{PS} \ln PS_{jn}$ で表し、重複が全くない経路で $\beta_{PS} \ln PS_{jn} = 1$


問題 1 : 全経路選択肢の列挙が必要

問題 2 : リンク加法的ではない

→ RLモデルには適用不可能

# 番外編 LS (リンクサイズ属性) とIIA特性の緩和

## ● Fosgerauの提案：Link Size (LS)の導入



- ズレ
- 普通MNL → 全て  $\frac{1}{4}$  の選択確率
  - 左右に半分くらい分かれて {1,5} に  $\frac{1}{2}$  くらい
- ズレを補正するためにリンクの共有を考える

## ● リンクサイズ属性 (LS)

- 重複量の代理として期待リンクフロー  $F(a)$  を使用する  
cf. リンク  $a$  を通る経路数 @PS属性 (PSLモデル)

- 定義

$$LS^{od} = F^{od}(\tilde{\beta})$$

$LS^{od}$  : あるODに対する  $(A \times 1)$  のベクトル ( $k$  番目の要素はリンク  $k$  のLS属性)

$\tilde{\beta}$  : 効用の計算に使用した説明変数のパラメータ  $\beta$  の推定値は  $\hat{\beta}$  とは区別する

$F^{od}(\tilde{\beta})$  は スタートアップゼミ2022 #2 資料のp.39 の  $(I - P^d(\tilde{\beta})^T) F^{od}(\tilde{\beta}) = G^o$  から算出

$G^o$  : オリジナルリンクが1、他が0の値を持つ発生フローベクトル

$G^o \mathbf{1} = 1$  より、 $F^{od}$  は正規化されたとも

**課題 1** 経路同士の相関を考慮できない (LS 以外にIIA特性が残る)

# 2. Recursive Logit Model

## ● Bellman方程式を解く

$$V_n^d(k) = E \left[ \max_{a \in A(k)} (v_n(a|k) + V_n^d(a) + \mu \varepsilon_n(a)) \right] \quad \forall k \in A$$

※ 以下、個人 $n$ の添字を省略し、 $V_n^d(k) = V^d(k)$  とする

- 対数をとる

$$e^{\frac{1}{\mu} V^d(k)} = \begin{cases} \sum_{a \in A} \delta(a|k) e^{\frac{1}{\mu} (v(a|k) + V^d(a))} & \forall k \in A \\ 1 & k = d \end{cases}$$

- $M^d$  ( $|\tilde{A}| \times |\tilde{A}|$ )なる接続行列を次のように定義

$$M_{ka} = \delta(a|k) e^{\frac{1}{\mu} v(a|k)} = \begin{cases} e^{\frac{1}{\mu} v(a|k)} & \text{if } a \in A(k) \\ 0 & k = d \end{cases} \quad (\because d \text{はダミーリンクなので後続なし})$$

- $b^d$  ( $|\tilde{A}| \times 1$ ) と  $z^d$  ( $|\tilde{A}| \times 1$ ) を定義

$$b_k^d = \begin{cases} 0 & k \neq d \\ 1 & k = d \end{cases} \quad z_k^d = e^{\frac{1}{\mu} v(k)}$$

- 期待効用  $z$  は連立一次方程式  $\boxed{z^d = M^d z^d + b^d}$  の解

目的地 $d$ ごとに1つの線形システム

---

**課題 2** 多数の大規模な連立方程式を解く必要性 → 計算時間コストが高い  
→ 大規模NW・複雑なモデルに適用困難

スタートアップゼミ2022 #2 参照

# 3. Decomposition method - DeC method

- $D$ : 観測された目的地の集合( $d \in D$ )
- $(|\tilde{A}| + 1) \times (|\tilde{A}| + 1)$ の行列  $\mathbf{M}^0$  と  $(|\tilde{A}| + 1) \times (|\tilde{A}| + 1)$ の行列  $\mathbf{U}^d$  と定義

$$M^0_{ka} = \begin{cases} M_{ka} & \text{if } k, a \in A(k) \\ 0 & \text{otherwise} \end{cases} \quad U^d_{ka} = \begin{cases} \delta(d|k)e^{\frac{1}{\mu}v(d|k)} & \text{if } a = d \\ 0 & \text{otherwise} \end{cases}$$

- 全ての $d$ について  $\mathbf{M}^d = \mathbf{M}^0 + \mathbf{U}^d$

$$\underbrace{\begin{pmatrix} m_{1,1} & m_{1,2} & \cdots & m_{1,|\mathcal{A}|+1} \\ m_{2,1} & m_{2,2} & \cdots & m_{2,|\mathcal{A}|+1} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{pmatrix}}_{\mathbf{M}^d} = \underbrace{\begin{pmatrix} m_{1,1} & m_{1,2} & \cdots & 0 \\ m_{2,1} & m_{2,2} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{pmatrix}}_{\mathbf{M}^0} + \underbrace{\begin{pmatrix} 0 & 0 & \cdots & m_{1,|\mathcal{A}|+1} \\ 0 & 0 & \cdots & m_{2,|\mathcal{A}|+1} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{pmatrix}}_{\mathbf{U}^d}$$

- $V^d(d) = 0$  から、 $z^d_{|\mathcal{A}|+1} = e^{\frac{1}{\mu}V^d(d)} = e^0 = 1$  and

$$\mathbf{U}^d \mathbf{z}^d = \begin{pmatrix} 0 & 0 & \cdots & m_{1,|\mathcal{A}|+1} \\ 0 & 0 & \cdots & m_{2,|\mathcal{A}|+1} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{pmatrix} \begin{pmatrix} z^d_1 \\ z^d_2 \\ \vdots \\ z^d_{|\mathcal{A}|+1} \end{pmatrix} = \begin{pmatrix} m_{1,|\mathcal{A}|+1} \\ m_{2,|\mathcal{A}|+1} \\ \vdots \\ 0 \end{pmatrix}$$

以上から

行列  $\mathbf{U}^d$  の最終列  
↓

$$\mathbf{z}^d = \mathbf{M}^d \mathbf{z}^d + \mathbf{b}^d = (\mathbf{M}^0 + \mathbf{U}^d) \mathbf{z}^d + \mathbf{b}^d = \mathbf{M}^0 \mathbf{z}^d + \mathbf{U}^d \mathbf{z}^d + \mathbf{b}^d = \mathbf{M}^0 \mathbf{z}^d + \mathbf{t}^d + \mathbf{b}^d$$



# 3. Decomposition method - DeC method

**仮定1**  $k \in A, a \in A(k), a \neq D$  のもとで、即時効用  $v(a|k)$  は独立かつ目的地  $d \in D$  に対して独立

→ 個人または目的地に固有の属性は存在しない

$$M^0 \text{は} \forall d \in D \text{において独立} \leftarrow M^0_{ka} = \begin{cases} M_{ka} = \begin{cases} e^{\frac{1}{\mu} v(a|k)} & \text{if } a \in A(k) \\ 0 & \text{otherwise} \end{cases} \\ 0 \end{cases}$$

- $(|\tilde{A}| + 1) \times |D|$  の行列  $\mathbf{Z}$  を定義 と  $(|\tilde{A}| + 1) \times |D|$  の行列  $\mathbf{B}$  を定義

$$\mathbf{Z} = [z^{d_1}, z^{d_2}, \dots, z^{d_{|D|}}] \text{ for } \forall d \in D \quad \mathbf{B} = \mathbf{t}^d + \mathbf{b}^d \text{ for } \forall d \in D$$

- これにて以下の新しい連立一次方程式を得る

$$\mathbf{Z} = \mathbf{M}^0 \mathbf{Z} + \mathbf{B} \Leftrightarrow (\mathbf{I} - \mathbf{M}^0) \mathbf{Z} = \mathbf{B} \quad \dots (5)$$

- $\mathbf{I} - \mathbf{M}^0$  が可逆(逆行列を持つ)場合、一意の解  $\mathbf{Z}$  を持つ
- $\mathbf{I} - \mathbf{M}^0$  が可逆となる条件は Fosgerau(2013) から拡張可能

- LL関数の勾配と Hessian 行列も、 $\mathbf{Z}$  の Jacobian を導出することで得られる

ベクトル  $\mathbf{Z}$  はすべての目的地に対する全価値関数が含まれている

**解決策 2** 一次方程式(5)を1度だけ解けばよい → 計算時間コスト削減

→ 大規模NW・複雑なモデルへの適用可能性

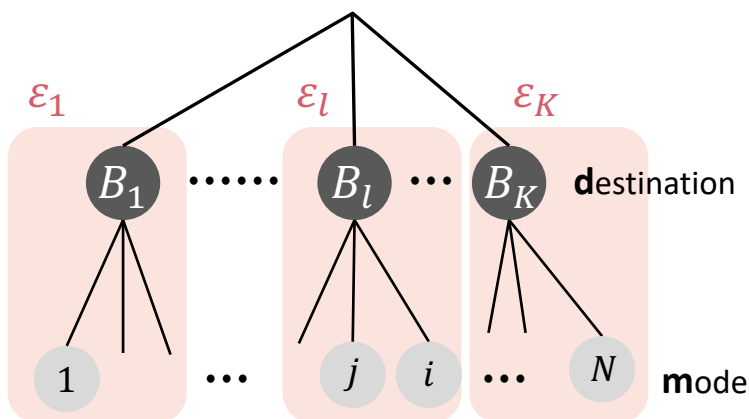
# 復習編 Nested Logit Model (NL)

= 2 種類のスケールパラメータを使った選択確率の記述

例) 交通手段選択

$$d = 1, 2, \dots, l, \dots, K$$

$$m = 1, 2, \dots, j, i, \dots, N$$



$$U_{dm} = V_d + V_m + V_{dm} + \varepsilon_d + \varepsilon_{dm}$$

$U_{dm}$ : 選択肢( $d, m$ )の真の効用

$V_d$ : 目的地選択肢 $d$ に特有な効用の確定項

$V_m$ : 手段選択肢 $m$ に特有な効用の確定項

$V_{dm}$ : 選択肢( $d, m$ )に特有な効用の確定項

$\varepsilon_d$ : 目的地選択肢 $d$ に特有な効用の確率項

→ スケールパラメータ $\mu_d$ の*i. i. d.*ガンベル分布に従う

$\varepsilon_{dm}$ : 選択肢( $d, m$ )に特有な効用の確率項

→ スケールパラメータ $\mu$ の*i. i. d.*ガンベル分布に従う

$$V'_d = \frac{1}{\mu} \ln \sum_{m'} \exp\{\mu(V_{m'} + V_{dm'})\}$$

$$\varepsilon'_d = \max_{m'} (V_m + V_{dm} - \varepsilon_{dm}) - V'_d$$

とにおいて、選択確率は

$$P(d, m) = \frac{\exp\{\mu(V_m + V_{dm})\}}{\sum_{m'} \exp\{\mu(V_{m'} + V_{dm'})\}} \cdot \frac{\exp\{\mu_d(V_d + V'_d)\}}{\sum_d \exp\{\mu_d(V_d + V'_d)\}}$$

スタートアップゼミ2022 #2 参照

# 番外編 NRLモデル (Mai et al. 2015 a)

## RLモデル

**解決 0** 経路の選択肢集合が不明

**課題 1** 経路同士の相関 ← 不十分 !!! ※ LS 以外の要素に対して IIA 特性が残る


## Nested RLモデル

スケールパラメータを各リンクに固有に与えることでIIA特性を緩和 (= 選択確率が変化)


-Mai et al. 2015 の検証-

スケールパラメータの設定

$$\mu_a = 0.5 \quad \mu_b = 0.8 \quad \text{others } \mu = 1$$



- IIA特性は緩和
- 代替のされ方はNW構造に依存



Paths	Probabilities with link removed				
	Original	a <sub>1</sub>	a <sub>2</sub>	b <sub>1</sub>	b <sub>2</sub>
1 : [o,a,a <sub>1</sub> ,d]	0.54 -		0.65	0.55	0.56
2 : [o,a,a <sub>2</sub> ,d]	0.15	0.38 -		0.16	0.16
3 : [o,a,a <sub>3</sub> ,e,d]	0.04	0.05	0.05	0.05	0.05
4 : [o,b,b <sub>1</sub> ,e,d]	0.02	0.05	0.03 -		0.03
5 : [o,b,b <sub>2</sub> ,d]	0.06	0.12	0.07	0.17 -	
6 : [o,b,b <sub>3</sub> ,d]	0.17	0.33	0.2	0.18	0.21

## 4-2. 番外編 Mixed logit の定式化と理解

### Mixed logit とは

- 誤差項に**正規分布**を仮定したプロビット系列のモデルと誤差項に**ガンベル分布**を仮定したモデルを組み合わせたもの
- MNLの選択確率のパラメータを確率分布によって扱うことで母集団内でのばらつきを表現

→ **誤差相関**や異分散性を表現可能

### 定式化

$\omega$ で評価されたロジット型確率式

$$L_{ni}(\omega) = \frac{e^{V_{ni}(\omega)}}{\sum_{j=1}^J e^{V_{nj}(\omega)}}$$

→ 選択確率

$$P_{ni} = \int L_{ni}(\omega) f(\omega) d\omega$$


確率密度関数(=確率分布)

$V_{ni}(\omega)$ : 効用の確定部分( $\omega$ の関数)

$\omega$ : ランダム係数

確率密度関数  $f(\omega)$

- $f(\omega)$ は離散、連続どちらもあり得る(ただし多くの場合で連続型を用いる)  
※ 後述:  $f(\omega)$ はパラメータ $\theta$ の関数  $f(\omega|\theta)$
- $\omega$ の平均を $b$ とすると  
 $f(\omega) = 1$  for  $\omega = b$ ,  $0$  for  $\omega \neq b$   
となるとき、通常のロジットモデル



## 4-2.番外編 Mixed logit の定式化と理解

パラメータが個人 $n$ によって異なると考えるとき

個人ごとに異なる $\omega_n$  (真の値) を実際に観測することはできない  
→ 確率密度関数 $f(\omega)$ によって表現

→ 個人 $n$ が $J$ 個の選択肢から選択肢 $j$ を選択したときの効用

$$U_{nj} = V_{nj} + \varepsilon_{nj} = \omega'_n x_{nj} + \varepsilon_{nj}$$

$\omega_n$ は個人によって異なる→  $f(\omega)$ に従って $\omega'_n$ となる、とおく

$$\left( \begin{array}{l} \text{cf. } \omega_n \text{ が定数 } \omega'_n \text{ であるとするれば確率式はロジットモデルと同様に} \\ \text{=パラメータが個人 } n \text{ で共通} \\ L_{ni}(\omega) = \frac{e^{\omega'_n x_{nj}}}{\sum_{j=1}^J e^{\omega'_n x_{nj}}} \text{ とかける。} \end{array} \right)$$

$\omega_n$ が $f(\omega)$ に従って変動するため $\omega$ に対して積分する必要がある、

選択確率は

$$P_{ni} = \int \left( \frac{e^{\omega'_n x_{ni}}}{\sum_{j=1}^J e^{\omega'_n x_{nj}}} \right) f(\omega) d\omega$$

**Mixed logitにはIIA特性がない**


$\frac{P_{ni}}{P_{nj}}$ は選択肢 $i, j$ 以外を含む全データに依存

**解決策 1** 理論的には、Mixed logit型のRLを用いれば、**IIA特性を緩和可能**

## 4-2. 番外編 Mixed logit と Error Component ; 誤差相関

異なる選択肢間の誤差項の相関を考える場合

課題 1 2つの経路は無関係に独立???



$$U_{nj} = \alpha' x_{nj} + \mu'_n z_{nj} + \varepsilon_{nj}$$

$x_{nj}, z_{nj}$  :  $j$ に関する観測値ベクトル

$\alpha$  : 固定された係数ベクトル

$\mu_n$  : 平均0の変動する係数ベクトル

$\varepsilon_{nj}$  : *i.i.d.*の誤差項

効用関数は、

$$U_{nj} = \alpha' x_{nj} + \sum_{k=1}^K \mu_{nk} d_{jk} + \varepsilon_{nj}$$

### Nested Logit の考え方

ネスト構造を表現するダミー変数

$$\mu'_n z_{nj} = \sum_{k=1}^K \mu_{nk} d_{jk}$$

$$d_{jk} = \begin{cases} 1 & \text{選択肢 } j \text{ がネスト } k \text{ に含まれる} \\ 0 & \text{選択肢 } j \text{ がネスト } k \text{ に含まれない} \end{cases}$$

$$\mu_{nk} \sim N(0, \sigma_k)$$

## 4-2. 番外編 Mixed logit と Error Component ; 誤差相関

異なる選択肢間の誤差項の相関を考える場合

$$U_{nj} = \alpha' x_{nj} + \mu'_n z_{nj} + \varepsilon_{nj} \xrightarrow{\text{NL Analogy}} U_{nj} = \alpha' x_{nj} + \sum_{k=1}^K \mu_{nk} d_{jk} + \varepsilon_{nj}$$

$\mu_{nk} \sim N(0, \sigma_k)$

$z_{nj}$  も誤差項なので、  
 $\varepsilon_{nj}$  とまとめて効用の確率項  $\eta_{nj}$  とおく

$$\eta_{nj} = \mu'_n z_{nj} + \varepsilon_{nj}$$

選択肢  $i$  と選択肢  $j$  の誤差相関は

$$\text{Cov}(\eta_{ni}, \eta_{nj}) = E(\mu'_n z_{ni} + \varepsilon_{ni})(\mu'_n z_{nj} + \varepsilon_{nj}) \longrightarrow \text{Cov}(\eta_{ni}, \eta_{nj}) = E(\mu_{nk} + \varepsilon_{ni})(\mu_{nk} + \varepsilon_{nj}) = \sigma_k$$

ネスト  $k$  に含まれる選択肢の共分散は

$$\text{Var}(\eta_{ni}) = E(\mu_{nk} + \varepsilon_{ni})^2 = \sigma_k + \frac{\pi^2}{6}$$

ネスト  $k$  内の相関係数

$$\frac{\sigma_k}{\sigma_k + \frac{\pi^2}{6}} : \text{ネスト } k \text{ に依存}$$

各ネストの誤差項の分散が等しい場合は  
 $\sigma_k = \sigma \text{ for } k = 1, 2, \dots, K$

$$\frac{\sigma}{\sigma + \frac{\pi^2}{6}} = \text{Const.}$$

# 4. Mixed Recursive Logit Model

混合型          再帰的          ロジット

- 経路  $\sigma = \{k_i\}_{i=0}^J = \{k_0, k_1, \dots, k_J\}$  の選択確率

$$P(\sigma; \beta) = e^{-v^d(k_0; \beta)} \prod_{i=1}^J e^{v(k_{i+1}|k_i; \beta)}$$

- Mixed (MN)L の枠組みでは確定項  $v(k_{i+1}|k_i; \beta)$  自体がランダムな要素を含む

$$P(\sigma; \theta) = E_{\omega} [P(\sigma; \beta)] = \int P(\sigma; \theta, \omega) f(\omega) d\omega \quad \dots (6) \quad (\beta = \beta(\theta, \omega))$$

例：  $\beta$  が  $K$  次元の正規分布のランダムベクトルの場合

$$\omega = (\omega_1, \dots, \omega_K) \text{ with } \omega_i \sim N(0, 1)$$

$\theta$  で  $\beta$  の平均 (means) ・ 標準偏差 (SD : Standard Deviation) を決定

$$\left\{ \begin{array}{l} f(\cdot) : \text{確率密度} \\ \theta : \text{LL関数(対数尤度関数)最大化によって推定されるパラメータ} \end{array} \right.$$

- 経路選択結果の観測集合  $n = 1, 2, \dots, N$  に対して、  $LL(\theta) = \frac{1}{N} \sum_{n=1}^N \ln P(\sigma_n; \theta)$

個体  $n$  あたり 1 つの多次元積分 = 解析解は得られない

→ 求積法 or シミュレーションによって 数值的に近似 する

---

**課題 2** 複雑なモデル において計算コストが膨大過ぎる



# 4. Mixed Recursive Logit Model

再掲：  $P(\sigma; \theta) = E_{\omega}[P(\sigma; \beta)] = \int P(\sigma; \theta, \omega) f(\omega) d\omega \dots (6)$

- 数値的に近似すると (求積法 or シミュレーション法)

$$\tilde{P}_{R_n}(\sigma_n; \theta) = \sum_{i=1}^{R_n} v_{n,i} P(\sigma_n; \theta, \omega_{n,i}) \dots (7)$$

$\omega_{n,i}$  : 数値積分の分点  
 $v_{n,i}$  : 数値積分の重み

- 特にモンテカルロ法では、積分分点  $\omega_{n,i}$  は  $\omega$  の分布からランダムに描かれる

$$\tilde{P}_{R_n}(\sigma_n; \theta) = \frac{1}{R_n} \sum_{i=1}^{R_n} P(\sigma_n; \theta, \omega_{n,i}) \dots (8)$$

※ モンテカルロ法では抽選数  $R_n \rightarrow \infty$  で真の最尤推定値に収束する (Bastin et al. 2006)

- DeC法は(7)の形の任意の近似に適用可能
- ただしDeC法の最大の強みである「**解くべき線形システムを1本にする**」を満たすため以下の条件で制限

**条件：積分分点は観測経路  $n$  に関わらず共通**

$$R_n \equiv R, \quad v_{n,i} \equiv v_i, \quad \omega_{n,i} \equiv \omega_i, \quad n = 1, 2, \dots, N$$


※ 選択確率のシミュレーション・バイアスは  $R \rightarrow \infty$  で  $|\tilde{P}_{R_n}(\sigma_n; \theta) - \tilde{P}_{R_m}(\sigma_m; \theta)| \rightarrow 0$  (証明は論文中) → 検証

力不足

**解決策 2** Mixed RL モデル では異なる積分分点ごとに線形システム(5)を解く必要 → 計算コスト **膨大**

**解決策 2<sup>α</sup>** + 積分分点が観測経路  $n$  間でみな同じであるという条件 → 解くべき一次方程式を1つに

# 4-1. Mixed Recursive Logit Model - IRNとCRNの比較実験



2つの起点ノード：{a, b}

4つの目的地ノード：{d, c, e, f}

8つの観測ODペア

8つの観測ODペア各々に5つの経路→40経路

$TT(a)$ ：リンク  $a$  の移動時間 ( $[0,1]$ )

- シミュレーションにおける乱数生成方法

**IRL (independent random numbers)**

= 観測OD毎に  $\omega_{n,i}$  を独立に抽選 (既往研究)

**CRL (common random numbers)**

= 観測OD共通のセットで抽選 ( $\omega_{n,i} \equiv \omega_i$ ) (提案)

- 即時効用  $u(a|k) = \beta_1 TT(a) + \beta_2 + \varepsilon(a)$

$\beta_1, \beta_2$ : 正規分布     $\varepsilon$ : i.i.d.ガンベル

$\beta_1 \sim N(\theta_{TT}, \sigma_{TT}^2)$      $\beta_2 \sim N(0, \sigma^2)$

- モンテカルロドローを50、200、1000回で比較
- 100回の独立した推定の平均値を推定値として採用

## 実験結果

1. 抽選回数が十分に大 (1000回) → 5%の有意水準で最終尤度はIRNとCRNで有意な差はない  
→ **CRNは標準的なIRNに代わる方法**
2. **DeC法は計算時間を10~50倍も短縮 (高速化)**

※ IRN→CRNはLL計算コストに影響微小 (最適化アルゴリズムの反復回数をわずかに削減するのみ)

# 課題整理

～4章

複雑なモデル

課題 1 → 解決策 1 Mixed RLモデル の採用 → IIA特性が緩和

理論的に可能

課題 2 → 解決策 2<sup>+α</sup> Decomposition method (DeC method) を提案 → 簡易NWで高速化を確認

実際に可能？

複雑な実際のデータ（複雑なNW・膨大な観測OD）で計算コスト的に推定可能？  
複雑なモデル（Mixed RLモデル）で計算コスト的に推定可能 ??? 推定精度は??

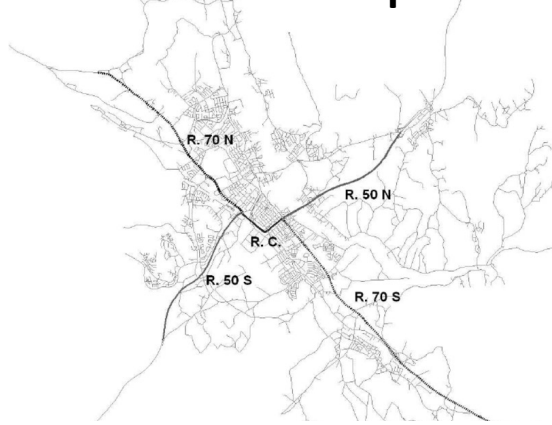
## 5章 + 6章 複雑な実際の Data setにおけるMixed RLモデルを用いた推定

		Data set 1 Car	Data set 2 Bicycle		
ネットワーク	リンク数	7459	42,372		
	ノード数	3077	16,352		
サンプル	経路数	21,452	127,001		
	目的地	1832	648		
モデルパラメータ数		4	14		
Estimation method		DeC	Original	DeC	Original
計算時間 (sec)	価値関数	2	90	10	235
	LL及び勾配計算	10	284	54	1605
	総推定時間	230	6670	4824	144,110

約30倍高速

# 6-1. Mixed RLモデルに対するDeC法の計算結果 -モデルの仕様

## 5 subnetwork components



Borlänge Road Network and **Subnetwork Definition** (Frejinger and Bierlaire, 2007)

$TT(a)$ : リンク  $a$  の移動時間

$LT(a|k)$ : 左旋回ダミー (リンク  $a$  から  $k$  への旋回角度  $\alpha_{LT}$  が  $40^\circ < \alpha_{LT} < 177^\circ \rightarrow 1$ )

$UT(a|k)$ : Uターンダミー (リンク  $a$  から  $k$  への旋回角度  $\alpha_{LT}$  が  $\alpha_{LT} > 177^\circ \rightarrow 1$ )

$LC(a)$ : リンク定数 (本実験ではすべてのリンクで1と設定)

$LS(a)$ : リンクサイズ (Fosgerau:2013)

$\varepsilon(a) \sim i.i.d.$  ガンベル

$$\beta_{TT}^* \sim N(\mu_{TT}, \sigma_{TT}^2)$$

$$\zeta \sim N(0, 1)$$

$$F(a)_q$$

size=5のvector  
 $q$ : subnetwork

$$F(a)_q = \begin{cases} 0 & \text{if } a \notin q \\ \sqrt{TT(a)} & \text{otherwise} \end{cases}$$

$$T(\sigma) = \text{diag}(\sigma_{R.50N}, \sigma_{R.50S}, \sigma_{R.70N}, \sigma_{R.70S}, \sigma_{R.C})$$

$$\sigma = \{\sigma_{R.50N}, \sigma_{R.50S}, \sigma_{R.70N}, \sigma_{R.70S}, \sigma_{R.C}\}$$

### ● RL

$$u^{RL}(a|k; \beta) = \beta_{TT} TT(a) + \beta_{LT} LT(a|k) + \beta_{LC} LC(a) + \beta_{UT} UT(a|k) + \varepsilon(a)$$

### ● RL with LS属性 ; RL-LS

$$u^{RL \cdot LS}(a|k; \beta) = \beta_{TT} TT(a) + \beta_{LT} LT(a|k) + \beta_{LC} LC(a) + \beta_{UT} UT(a|k) + \beta_{LS} LS(a) + \varepsilon(a)$$

### ● Mixed RL with random parameters ; MRL-RP

$$u_{RP}^{MRL}(a|k; \beta) = \beta_{TT}^* TT(a) + \beta_{LT} LT(a|k) + \beta_{LC} LC(a) + \beta_{UT} UT(a|k) + \varepsilon(a)$$

### ● Mixed RL with EC ; MRL-EC

$$u_{EC}^{MRL}(a|k; \beta, \sigma) = \beta_{TT} TT(a) + \beta_{LT} LT(a|k) + \beta_{LC} LC(a) + \beta_{UT} UT(a|k) + F(a)^T T(\sigma) \zeta + \varepsilon(a)$$

### ● Mixed RL with EC and random parameters ; MRL-REC

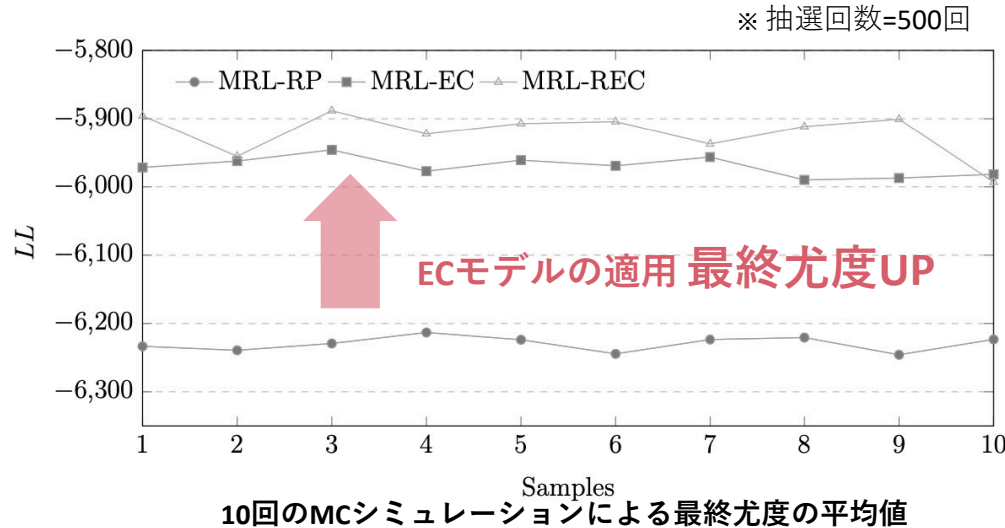
$$u_{REC}^{MRL}(a|k; \beta, \sigma) = \beta_{TT}^* TT(a) + \beta_{LT} LT(a|k) + \beta_{LC} LC(a) + \beta_{UT} UT(a|k) + F(a)^T T(\sigma) \zeta + \varepsilon(a)$$

## 6-2. Mixed RLモデルに対するDeC法の計算結果 -適合度検証

複雑な実際のデータ（複雑なNW・膨大な観測OD）で計算コスト的に推定可能?  
 複雑なモデル（Mixed RLモデル）で計算コスト的に推定可能?? 推定精度は??

### 計算コスト

DeCを用いない場合数ヶ月かかるMixed RLモデルを用いた推定が**3-5日程度で可能** = **実際に可能**



尤度比検定の結果


Models	$\chi^2$	$p$ value
RL & MRL-RP	148.42	3.84e-34
RL & MRL-EC	667.22	6.00e-142
MRL-RP & MRL-REC	616.16	6.52e-131
MRL-EC & MRL-REC	97.36	5.78e-23

### 適合度検証

尤度比検定の結果から、Mixed RLモデルはRLモデルよりも**適合度が高い**

# 6-3. Mixed RLモデルに対するDeC法の計算結果 - 予測性能

## ● クロスバリデーションによる予測性能比較

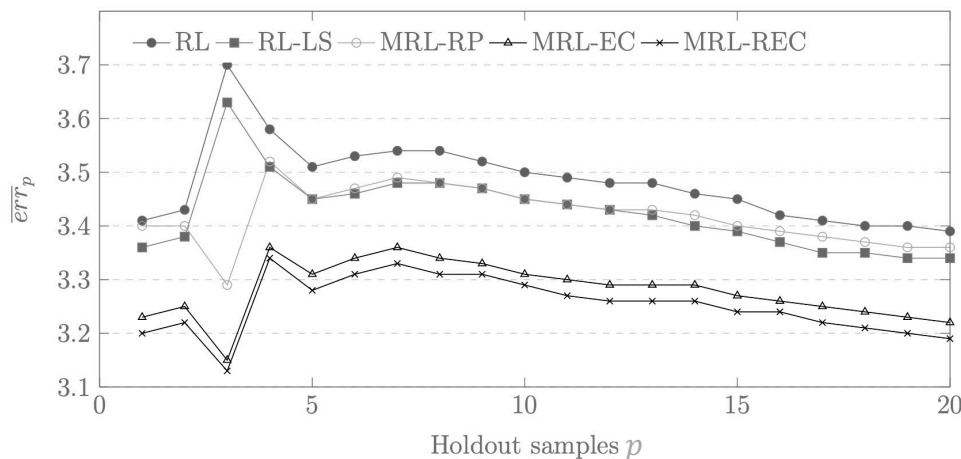


● 検定誤差 ※  $|PS_i|$ : サンプルサイズ

$$err_i = -\frac{1}{|PS_i|} \sum_{\sigma_j \in PS_i} \ln \tilde{P}^R(\sigma_j, \hat{\theta}_i) \quad 1 \leq i \leq 20$$

● 検定誤差の平均値

$$\overline{err}_p = \frac{1}{p} \sum_{i=1}^p err_i \quad \forall 1 \leq p \leq 20$$



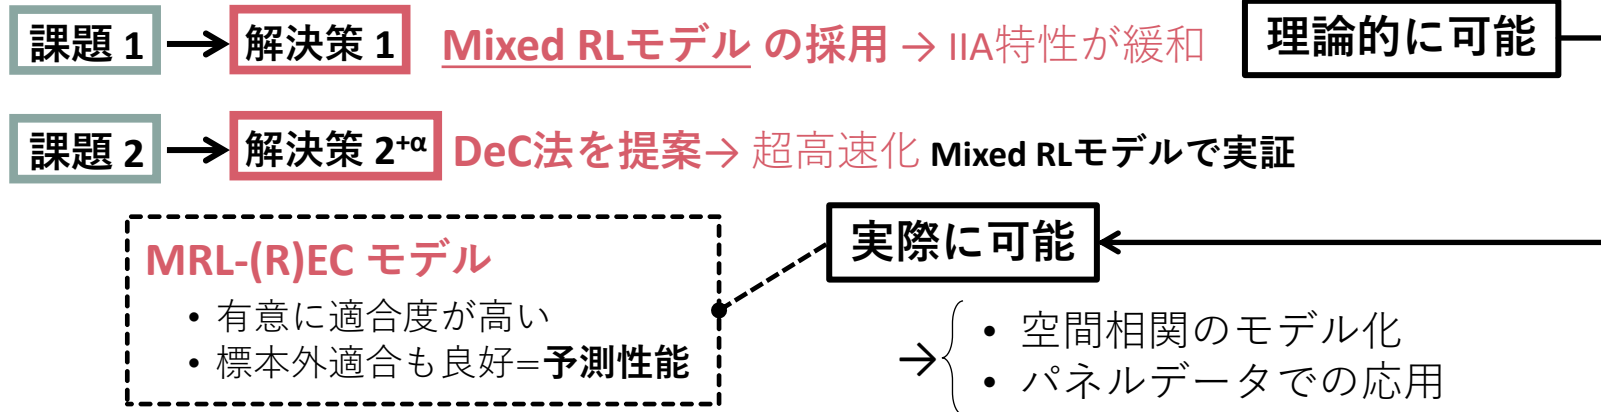
● Mixed RLモデルはRLモデルよりも**予測性能**が優れている

● 特に**MRL-(R)ECモデル**は他のモデルに比較して

- ・ サンプル内適合度が著しく高い
- ・ サンプル外適合度も高い

# 7. まとめと課題の整理

## 本論文の成果まとめ



## 課題の整理

- **個人や目的地の異質性に対応できない**
  - DeC法適用のための“条件”(p.16参照)を設定しているため
  - 属性が目的地固有の場合 例:LS属性
  - 効用が旅行者の特性に依存する場合 例:年齢、収入etc.
    - \* 個人の異質性の考慮は行動原理の重要事項なので致命的では?
    - \* 属性が各クラスで個々に独立であるようにグループ化し、各クラスにDeC法を適用
- **多変量極限分布の誤差項を持つモデルには未対応**
  - 価値関数がそもそも線形方程式の形ではなく、DeC法を適用できない

## RL model と 経路相関

- [1]夏学期ゼミ2021 #8 発表資料 <http://bin.t.u-tokyo.ac.jp/szemi21/#6-2>
- [2]理論輪読会2020 #5-2 発表資料 <http://bin.t.u-tokyo.ac.jp/rzemi20/#5-2>

## Nested RL model

- [3]夏の理論合宿2018 #1-5 発表資料 <http://bin.t.u-tokyo.ac.jp/summercamp2018/>
- [4]理論談話会2016 #4-1 発表資料 <http://bin.t.u-tokyo.ac.jp/rzemi16/>
- [5] Mai, T., Fosgerau, M., & Frejinger, E. (2015). A nested recursive logit model for route choice analysis. *Transportation Research Part B: Methodological*, 75, 100-112.
- [6]理論談話会2015 #6 発表資料 [http://bin.t.u-tokyo.ac.jp/rzemi15/file/6\\_miki.pdf](http://bin.t.u-tokyo.ac.jp/rzemi15/file/6_miki.pdf)

## クロスバリデーション

- [7] 【AI・機械学習】 ホールドアウト検証とK分割交差検証(K-foldクロスバリデーション) | モデル性能の評価 <https://di-acc2.com/analytics/ai/6498/>