

# 交通行動の分析とモデリング (北村、森川他)

Chap.6-1, 6-4 (p.103~108, 122~132)

行動モデル編 #2

交通研究室 学部四年

日下部 達哉

# Contents

1. 経路選択モデル
2. 多項プロビット(MNP)モデル
3. 多項ロジット(MNL)モデル
4. ネスティッドロジット(NL)モデル
5. クロスネスティッドロジット(CNL)モデル
6. GEVモデル
7. Network-GEVモデル

# 1. 経路選択モデル

➤ 選択肢は離散的→連続的な指標に落とし込む

- ① 選択肢の望ましさを表現する「効用」を導入
- ② 個人は、効用を最大化する選択肢を選択
- ③ 効用は、測定可能な確定項と、測定不可能な誤差項に分けられる

効用最大化理論


ランダム効用仮説

$$U_n = V_n + \epsilon_n \quad V_n = \sum_k (\beta_k * x_{n,k})$$

選択肢<sub>n</sub>の効用    効用の確定項    効用の誤差項    効用の確定項    k個の変数の線形結合 (費用、時間、...)

# 1. 経路選択モデル

- ④リンクを重複して使う経路が存在するため、  
誤差項に相関がある(経路選択モデルに特徴的)  
→相関にどう対処するかを考えて、モデルが発展



## 2. 多項プロビット(MNP)モデル

▶  $\epsilon = (\epsilon_1, \epsilon_2, \dots, \epsilon_N)$  が多変量正規分布に従う  
(平均値  $\mathbf{0}$ 、分散共分散行列  $\Omega$ )

○ 選択肢の間に相関がある場合、分散が違う場合でも、  
正しく推定できる

× 多重積分の計算が必要になる

(計算機の性能的に難しかった時代もあったが、  
今は改善されてきている)

### 3. 多項ロジット(MNL)モデル

- $\epsilon = (\epsilon_1, \epsilon_2, \dots, \epsilon_N)$  が独立で同一なガンベル分布に従う  
(ロケーションパラメータ(分布の位置)  $\eta_n$ )  
(スケールパラメータ(分布のばらつき)  $\mu$ )

○積分の計算を避けられる

$$\textcircled{1} \epsilon_{max} \sim IID\_Gumbel\left(\frac{1}{\mu} * \ln \sum_{n=1}^N \exp(\mu\eta_n), \mu\right)$$

$$\textcircled{2} F(\epsilon_{n1} - \epsilon_{n2}) = \frac{1}{(1 + \exp\{\mu(\eta_{n2} - \eta_{n1})\})}$$

### 3. 多項ロジット(MNL)モデル

➤ 選択肢1を選ぶ確率を求める

$$P_1 = Pr[V_1 + \epsilon_1 \geq \max_{n \neq 1} (V_n + \epsilon_n)]$$

$$U^* = V^* + \epsilon^* = \max_{n \neq 1} (V_n + \epsilon_n), \quad \epsilon_n \sim IID\_Gumbel(0, \mu)$$

$$U_n \sim IID\_Gumbel(V_n, \mu)$$

$$U^* \sim IID\_Gumbel\left(\frac{1}{\mu} * \ln \sum_{n=2}^N \exp(\mu V_n), \mu\right)$$

$$V^* = \frac{1}{\mu} * \ln \sum_{n=2}^N \exp(\mu V_n), \quad \epsilon^* \sim IID\_Gumbel(0, \mu)$$

### 3. 多項ロジット(MNL)モデル

➤ 選択肢1を選ぶ確率を求める

$$\begin{aligned} P_1 &= Pr[\epsilon^* - \epsilon_1 \leq V_1 - V^*] \\ &= \frac{1}{1 + \exp\{\mu(V^* - V_1)\}} \\ &= \frac{\exp(\mu V_1)}{\exp(\mu V_1) + \exp(\ln \sum_{n=2}^N \exp(\mu V_n))} \\ &= \frac{\exp(\mu V_1)}{\sum_{n=1}^N \exp(\mu V_n)} \quad (\text{積分を使わずに導出できた}) \end{aligned}$$



### 3. 多項ロジット(MNL)モデル

$$\frac{P_{n2}}{P_{n1}} = \frac{\exp(\mu V_{n2})}{\exp(\mu V_{n1})} = \exp(V_{n2} - V_{n1})$$

➤ IIA特性...選択確率の比は、その選択肢の効用の  
確定項のみで決まる

○ 選択肢の集合を部分的にしか知らない場合でも、  
正しく推定できる

× 選択肢の間に相関がある場合、正しく推定できない

### 3. 多項ロジット(MNL)モデル

#### 赤バス – 青バス問題

効用の確定項が同じ「自動車」「赤バス」「青バス」がある。



$$V_{\text{車}} = V_{\text{赤}}$$

$$P_{\text{車}} = P_{\text{赤}}$$

各々の選択確率: 1/2

### 3. 多項ロジット(MNL)モデル



$$V_{\text{車}} = V_{\text{赤}} = V_{\text{青}}$$

$$P_{\text{車}} = P_{\text{赤}} = P_{\text{青}}$$

各々の選択確率: 1/3

車: 1/2、赤: 1/4、青: 1/4  
では??


## 4. ネステッドロジット(NL)モデル

- 多項ロジットに「ネスト(グループに近い概念)」を導入
- ある選択肢は、似た選択肢の集団である  
「ネストのどれか一つ」に属する
- 「ネスト」内の選択肢がどれほど似ているか(どれほど  
相関しているか)を考慮する

○IIA特性を緩和することができる

× ネストの定義が難しい

× 一つのネストにしか所属できない



# 4. ネステッドロジット(NL)モデル

➤ 選択肢nを選ぶ確率を求める

① ネストを定義 ...  $(C_1, \dots, C_M)$

② ネスト内の相関度を定義 ...  $(\lambda_1, \dots, \lambda_M)$

※  $0 \leq \lambda \leq 1$  で、大きいほど相関が少ない

③ 選択肢nがネストCに属する ...  $P_n = P_C P_{n|C}$

ネストC  
における  
経路nの  
選択確率

ネストCの  
選択確率

$$P_C = \frac{\left( \sum_{n' \in C_m} \exp\left(\frac{V_{n'}}{\lambda_m}\right) \right)^{\lambda_m}}{\sum_{m'=1}^M \left( \sum_{n' \in C_{m'}} \exp\left(\frac{V_{n'}}{\lambda_{m'}}\right) \right)^{\lambda_{m'}}$$

$$P_{n|C} = \frac{\exp\left(\frac{V_n}{\lambda_m}\right)}{\sum_{n' \in C_m} \exp\left(\frac{V_{n'}}{\lambda_m}\right)}$$

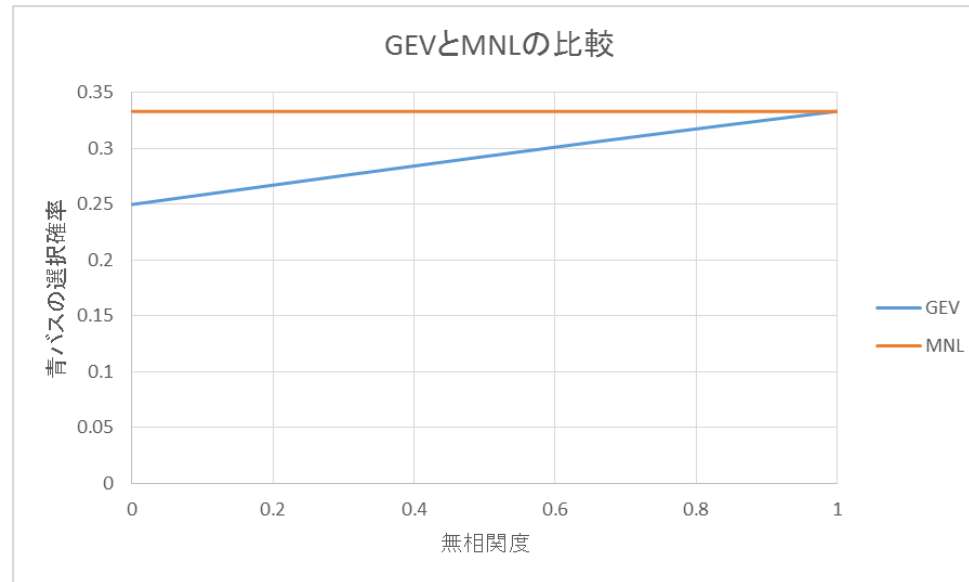
## 4. ネステッドロジット(NL)モデル

### 赤バス – 青バス問題

効用の確定項が同じ「自動車」「赤バス」「青バス」がある。ここで  $C_1 \ni$  車,  $C_2 \ni$  (赤, 青) とネストを定義

$$P_{\text{青}} = \frac{\exp\left(\frac{V_{\text{青}}}{\lambda_2}\right) * \left(\exp\left(\frac{V_{\text{赤}}}{\lambda_2}\right) + \exp\left(\frac{V_{\text{青}}}{\lambda_2}\right)\right)^{\lambda_2 - 1}}{\exp(V_{\text{車}}) + \left(\exp\left(\frac{V_{\text{赤}}}{\lambda_2}\right) + \exp\left(\frac{V_{\text{青}}}{\lambda_2}\right)\right)^{\lambda_2}}$$

# 4. ネステッドロジット(NL)モデル



無相関度0 (赤バスも青バスも全く同じ)

... 青バスの選択確率  $1/4$

無相関度1 (赤バスと青バスは全く違う)

... 青バスの選択確率  $1/3$


## 5. クロスネスティツドロジット(CNL)モデル

- ある選択肢は、似た選択肢の集団である  
「複数のネスト」に属する
- ネスト内の選択肢がどれほど似ているか(どれほど  
相関しているか)を考慮する
- ある選択肢がどれほどネストに帰属しているかを考慮する

○IIA特性を緩和することができる

○複数のネストに所属できる

×グループの定義が難しい





# 5. クロスネスティットロジット(CNL)モデル

➤ 選択肢nを選ぶ確率を求める

① ネストへの帰属度を定義 ...  $\alpha_{mn}$

※ 選択肢nがネストmにどれだけ帰属しているか

② 選択肢nが複数のネストに属する ...  $P_n = \sum_m P_m P_{n|m}$

ネストmに  
おける  
経路nの  
選択確率


ネストmの  
選択確率

$$P_m = \frac{\left( \sum_{n' \in C_m} (\alpha_{mn'} \exp(V_{n'}))^{\frac{1}{\lambda_m}} \right)^{\lambda_m}}{\sum_{m'=1}^M \left( \sum_{n' \in C_{m'}} (\alpha_{m'n'} \exp(V_{n'}))^{\frac{1}{\lambda_{m'}}} \right)^{\lambda_{m'}}$$

$$P_{n|m} = \frac{(\alpha_{mn} \exp(V_n))^{\frac{1}{\lambda_m}}}{\sum_{n' \in C_m} (\alpha_{mn'} \exp(V_{n'}))^{\frac{1}{\lambda_m}}}$$

## 6. GEVモデル


- PCLモデル...選択肢ごとに相関を考慮できる
- C-logitモデル／PSLモデル
  - ...リンク共有の度合いを表現する修正項を導入する
- GNLモデル...PCLモデルとCNLモデルを組み合わせる
- GEVモデル...ランダム効用理論に基づくこれらのモデル  
(NML, NL, CNL を含む)を統合的に表す
- $\epsilon = (\epsilon_1, \epsilon_2, \dots, \epsilon_N)$  が一般化極値分布に従う



# 6. GEVモデル

➤ 選択肢nを選ぶ確率を求める

ネストcにおける  
経路nの選択確率



$$P_{n|c} = \frac{y_n * \frac{\partial G}{\partial y_n}(y_1, \dots, y_N)}{\mu * G(y_1, \dots, y_N)}$$

$$y_n = \exp(V_n)$$

G ...  $\mu$ -GEV関数

MNL

$$G(y) = \sum_{n=1}^N y_n^\mu$$

NL

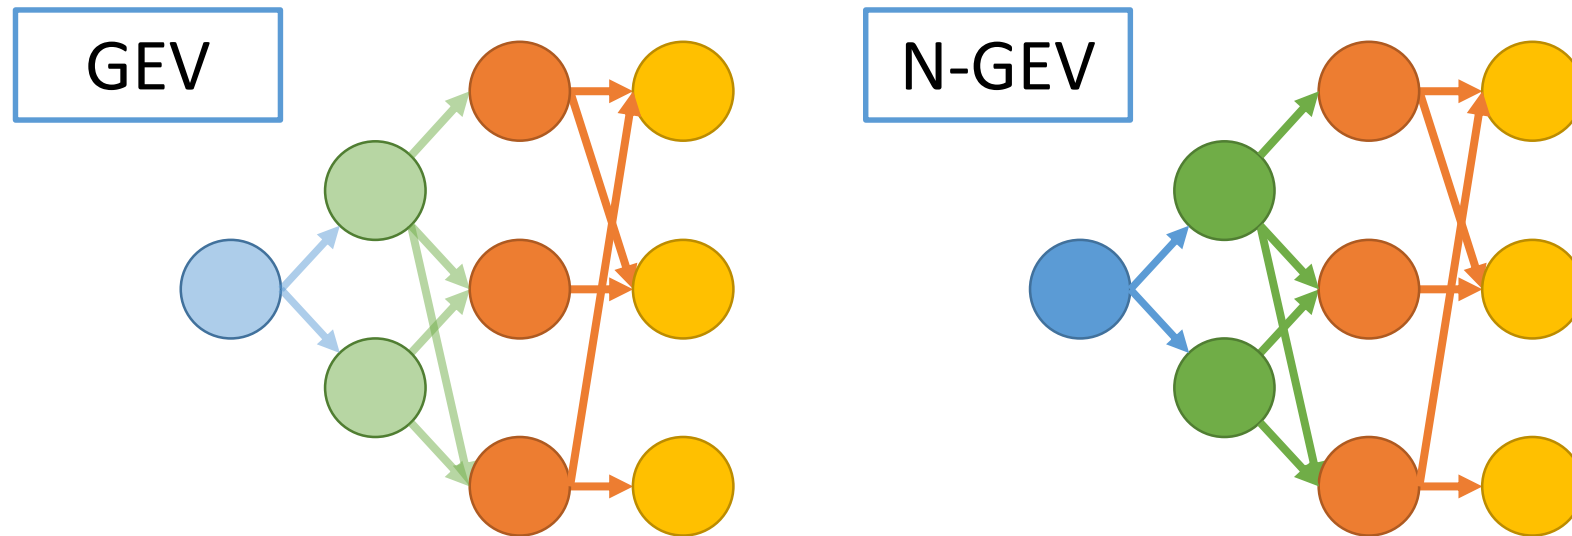
$$G(y) = \sum_{m=1}^M \left( \sum_{n=1}^{N_m} y_n^{\mu_m} \right)^{\frac{\mu}{\mu_m}}$$

CNL

$$G(y) = \sum_{m=1}^M \left( \sum_{n=1}^{N_m} \left( \alpha_{nm}^{\frac{1}{\mu}} y_n \right)^{\mu_m} \right)^{\frac{\mu}{\mu_m}}$$

# 7. NETWORK-GEVモデル

- GEVモデルでは「選択肢を決める段階」に着目
- Network-GEVでは「全ての段階」に着目  
...全ての段階に着目したら、ネスト構造そのものがネットワークのように見えてきた？



# 7. NETWORK-GEVモデル

- ▶ 上位ノード*i*を選んだとき、下位ノード*j*を選ぶ確率を求める

$$G^i(y) = \sum_{j \in succ(i)} \alpha_{ji} G^j(y)^{\frac{\mu_i}{\mu_j}}$$

↑  
上位ノード*i*  
における  
 $\mu_{GEV}$ 関数

↑  
下位ノード*j*  
における  
 $\mu_{GEV}$ 関数

$$P_{n|c} = \frac{y_n * \frac{\partial G}{\partial y_n}(y_1, \dots, y_N)}{\mu * G(y_1, \dots, y_N)}$$

↑  
ネスト*c*における  
経路*n*の選択確率

$$P_{j|i} = \frac{\alpha_{ji} (G^j)^{\frac{\mu_i}{\mu_j}}}{\sum_{j \in succ(i)} \alpha_{ji} (G^j)^{\frac{\mu_i}{\mu_j}}}$$

↑  
上位ノード*i*における  
下位ノード*j*の選択確率

