

# GEVモデル

2016/5/2

スタートアップゼミ#3

交通研4年 前田翠

1章 GEVモデルについて

2章 各モデルの導出

→スライド+板書+配布資料

3章 各モデルの特徴(CNL, GNL, n-GEV)

→配布資料にて

4章 スケールパラメータについて(NLを例として)

→配布資料にて

# 1章 GEVモデルについて

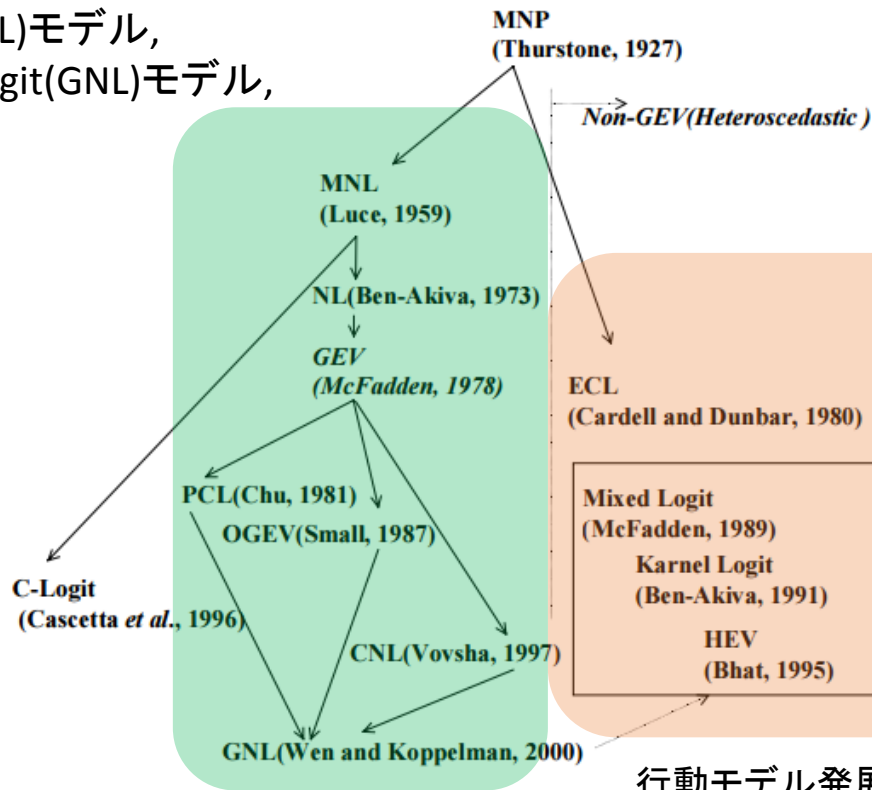
1-1.GEVモデルの位置づけ

1-2.GEVモデルとは

1-3.G関数とGEVモデル

## GEVファミリー

- McFaddenのGEV理論からの派生  
(e.g.)  
多項ロジット(MNL)モデル,  
Nested Logit(NL)モデル,  
Paired Combinatorial Logit(PCL)モデル,  
Cross-Nested Logit(CNL)モデル,  
Generalized Nested Logit(GNL)モデル,  
etc.



行動モデル発展の経緯 (羽藤,2002)

## 不等分散性グループ

- 効用関数の確率変動成分(誤差項)の不等分散性を考慮したもの  
(e.g.)  
Kernel Logitモデル,  
Mixed Logitモデル,  
多項プロビット(MNP)モデル,  
etc.

## GEVモデル

- ・多項ロジットモデルのIIA特性を緩和し、選択肢間の誤差相関を柔軟に表すことを可能としたモデル  
(青バス・赤バスのような問題が生じないようにする)
- ・選択確率がクローズドフォーム(積分形の残らない式)で書けるため、数値積分の必要がなく、計算負荷が低い
- ・あらゆる誤差相関のケースに対応したGEVモデルが存在する訳ではなく、表現したい誤差相関を持つGEVモデルが存在しない場合には必要に応じて自ら作る必要がある
- ・すべてのGEVモデルはG関数から導出することが出来る(後述)

## G関数が満たす4つの性質

## Train式定義

①  $G \geq 0$  for all positive values of  $Y_j \forall j$

② G関数は以下の式を満たす

$$G(\rho Y_1, \rho Y_2, \dots, \rho Y_J) = \rho G(Y_1, Y_2, \dots, Y_J)$$

③  $G \rightarrow \infty$  as  $Y_j \rightarrow \infty$  for any  $j$

④ Gのk次導関数を考えるとき、kが奇数の時は正、kが偶数のときは負

$$\frac{\partial G}{\partial Y_i} \geq 0$$

$$\frac{\partial^2 G}{\partial Y_i \partial Y_j} \leq 0$$

$$\frac{\partial^3 G}{\partial Y_i \partial Y_j \partial Y_k} \geq 0$$

## 一般的な定義

①  $G \geq 0$  for all positive values of  $y_j \forall j$

② G関数は以下の式を満たす

$$G(\rho y_1, \rho y_2, \dots, \rho y_J) = \rho^\mu G(y_1, y_2, \dots, y_J) \text{ for } \rho > 0$$

③  $G \rightarrow \infty$  as  $y_j \rightarrow \infty$  for any  $j$

④ Gのk次導関数を考えるとき、kが奇数の時は正、kが偶数のときは負

$$\frac{\partial G}{\partial y_i} \geq 0$$

$$\frac{\partial^2 G}{\partial y_i \partial y_j} \leq 0$$

$$\frac{\partial^3 G}{\partial y_i \partial y_j \partial y_k} \geq 0$$

## GEVモデルとG関数の関係

G関数から各モデルの選択確率 $P_i$ を導出することが可能。  
 表したい選択肢の誤差項同士の相関が、既存のモデルで表すことが出来ない場合は、独自にG関数を作ればそのG関数に対応する選択確率 $P_i$ を導出し、独自のモデルを作ることが可能。

### Train式定義

効用確定項 $V_i$ とすると

$$Y_i = \exp(\mu V_i)$$

$$P_i = \frac{Y_i}{G} \frac{\partial G}{\partial Y_i}$$

### 一般的な定義

効用確定項 $V_i$ とすると

$$y_i = \exp(V_i)$$

$$P_i = \frac{y_i}{\mu G} \frac{\partial G}{\partial y_i}$$

$0 \leq \mu \leq 1$ は選択肢 $i$ のスケールパラメータ  
 細かい説明は3章にて

## 2章 各モデルの導出

2-1.(確認してみよう!)MNLモデルの導出

2-2.(やってみよう!)NLモデルの導出

2-3.(参考資料)CNL, GNLの導出とn-GEVの確認



# 2-1.MNLモデルの導出

## Train式定義

- ①  $G \geq 0$  for all positive values of  $Y_j \forall j$
- ②  $G$ 関数は以下の式を満たす  
 $G(\rho Y_1, \rho Y_2, \dots, \rho Y_J) = \rho G(Y_1, Y_2, \dots, Y_J)$
- ③  $G \rightarrow \infty$  as  $Y_j \rightarrow \infty$  for any  $j$
- ④  $G$ の $k$ 次導関数を考えるとき、 $k$ が奇数の時は正、 $k$ が偶数のときは負

$$\frac{\partial G}{\partial Y_i} \geq 0$$


$$\frac{\partial^2 G}{\partial Y_i \partial Y_j} \leq 0$$

$$\frac{\partial^3 G}{\partial Y_i \partial Y_j \partial Y_k} \geq 0$$

## Train式MNLのG関数

$$G = \sum_{j=1}^J Y_j$$

- ①  $G = \sum_{j=1}^J Y_j = \sum_{j=1}^J \exp(V_j) \geq 0$
- ②  $G(\rho Y_j) = \sum_{j=1}^J \rho Y_j = \rho \sum_{j=1}^J Y_j = \rho G$
- ③  $G \rightarrow \infty$  as  $Y_j \rightarrow \infty$  for any  $j$
- ④  $\frac{\partial G}{\partial Y_i} = \frac{\partial}{\partial Y_i} (Y_1 + Y_2 + \dots + Y_i + \dots + Y_J) = 1 \geq 0$   
 $\frac{\partial^2 G}{\partial Y_i \partial Y_j} = 0 \leq 0$


 $G = \sum_{j=1}^J Y_j$  は G関数

## Train式定義

効用確定項 $V_i$ とすると

$$Y_i = \exp(\mu V_i)$$

$$P_i = \frac{Y_i}{G} \frac{\partial G}{\partial Y_i}$$

## Train式MNLの $P_i$ 導出

$$P_i = \frac{Y_i}{G} \frac{\partial G}{\partial Y_i} = \frac{Y_i}{\sum_{j=1}^J Y_j} 1 = \frac{\exp(\mu V_i)}{\sum_{j=1}^J \exp(\mu V_j)}$$

# 10 2-1.MNLモデルの導出

## 一般的な定義

- ①  $G \geq 0$  for all positive values of  $y_j \forall j$
  - ②  $G$ 関数は以下の式を満たす  
 $G(\rho y_1, \rho y_2, \dots, \rho y_J) = \rho^\mu G(y_1, y_2, \dots, y_J)$   
for  $\rho > 0$
  - ③  $G \rightarrow \infty$  as  $y_j \rightarrow \infty$  for any  $j$
  - ④  $G$ の $k$ 次導関数を考えるとき、 $k$ が奇数の時は正、 $k$ が偶数のときは負
- $$\frac{\partial G}{\partial y_i} \geq 0$$
- $$\frac{\partial^2 G}{\partial y_i \partial y_j} \leq 0$$
- $$\frac{\partial^3 G}{\partial y_i \partial y_j \partial y_k} \geq 0$$

## 一般的な定義


効用確定項 $V_i$ とすると  
 $y_i = \exp(V_i)$   
 $P_i = \frac{y_i}{\mu G} \frac{\partial G}{\partial y_i}$

$\mu$ は選択肢 $i$ のスケールパラメータ

## 一般的なMNLのG関数

$$G = \sum_{j=1}^J y_j^\mu$$

- ①  $G = \sum_{j=1}^J y_j^\mu = \sum_{j=1}^J \exp(\mu V_j) \geq 0$
- ②  $G(\rho y_j) = \sum_{j=1}^J \rho^\mu y_j^\mu = \rho^\mu \sum_{j=1}^J Y_j = \rho^\mu G$
- ③  $G \rightarrow \infty$  as  $y_j \rightarrow \infty$  for any  $j$
- ④  $\frac{\partial G}{\partial y_i} = \frac{\partial}{\partial y_i} (y_1^\mu + y_2^\mu + \dots + y_i^\mu + \dots + y_J^\mu)$   
 $= \mu y_i^{\mu-1} \geq 0$   
 $\frac{\partial^2 G}{\partial y_i \partial y_j} = 0 \leq 0 \quad \frac{\partial^2 G}{\partial y_i \partial y_i} = \mu(\mu-1)y_i^{\mu-2} \leq 0$

  $G = \sum_{j=1}^J Y_j$ はG関数

## 一般的なMNLの $P_i$ 導出

$$P_i = \frac{y_i}{\mu G} \frac{\partial G}{\partial y_i} = \frac{y_i}{\mu \sum_{j=1}^J y_j^\mu} \mu y_i^{\mu-1}$$

$$= \frac{y_i^\mu}{\sum_{j=1}^J y_j^\mu} = \frac{\exp(\mu V_i)}{\sum_{j=1}^J \exp(\mu V_j)}$$

## Train式定義

- ①  $G \geq 0$  for all positive values of  $Y_j \forall j$
- ②  $G$ 関数は以下の式を満たす  

$$G(\rho Y_1 \rho Y_2, \dots, \rho Y_j) = \rho G(Y_1, Y_2, \dots, Y_j)$$
- ③  $G \rightarrow \infty$  as  $Y_j \rightarrow \infty$  for any  $j$
- ④  $G$ の $k$ 次導関数を考えるとき、 $k$ が奇数の時は正、 $k$ が偶数のときは負

$$\frac{\partial G}{\partial Y_i} \geq 0$$

$$\frac{\partial^2 G}{\partial Y_i \partial Y_j} \leq 0$$

$$\frac{\partial^3 G}{\partial Y_i \partial Y_j \partial Y_k} \geq 0$$

## Train式定義

効用確定項 $V_i$ とすると

$$Y_i = \exp(V_i)$$

$$P_i = \frac{Y_i}{G} \frac{\partial G}{\partial Y_i}$$

## Train式NLのG関数

$$G = \sum_{l=1}^K \left( \sum_{j \in B_l} Y_j^{\frac{1}{\lambda_l}} \right)^{\lambda_l}$$

(やってみよう!!)

ネスト $B_1, B_2, \dots, B_K$ の中に選択肢 $1, 2, \dots, j, \dots$ が入っている

選択肢 $i$ がネスト $k$ に属しているとする...

Train式NLの $P_i$ 導出

$$P_i = \frac{Y_i}{G} \frac{\partial G}{\partial Y_i} = \frac{\exp\left(\frac{V_i}{\lambda_k}\right) \left(\sum_{j \in B_k} \exp\left(\frac{V_j}{\lambda_k}\right)\right)^{\lambda_k - 1}}{\sum_{l=1}^K \left(\sum_{j \in B_l} \exp\left(\frac{V_j}{\lambda_l}\right)\right)^{\lambda_l}}$$

## 一般的な定義

- ①  $G \geq 0$  for all positive values of  $y_j \forall j$
- ②  $G$ 関数は以下の式を満たす  

$$G(\rho y_1, \rho y_2, \dots, \rho y_J) = \rho^\mu G(y_1, y_2, \dots, y_J)$$
for  $\rho > 0$
- ③  $G \rightarrow \infty$  as  $y_j \rightarrow \infty$  for any  $j$
- ④  $G$ の $k$ 次導関数を考えるとき、 $k$ が奇数の時は正、 $k$ が偶数のときは負  

$$\frac{\partial G}{\partial y_i} \geq 0$$

$$\frac{\partial^2 G}{\partial y_i \partial y_j} \leq 0$$

$$\frac{\partial^3 G}{\partial y_i \partial y_j \partial y_k} \geq 0$$

## 一般的な定義

効用確定項 $V_i$ とすると

$$y_i = \exp(V_i)$$

$$P_i = \frac{y_i}{\mu G} \frac{\partial G}{\partial y_i}$$

$\mu$ は選択肢 $i$ のスケールパラメータ

## 一般的なNLのG関数

$$G = \sum_{l=1}^K \left( \sum_{j \in B_l} y_j^{\mu_l} \right)^{\frac{\mu}{\mu_l}}$$

(やってみよう!!)

ネスト $B_1, B_2, \dots, B_K$ の中に選択肢 $1, 2, \dots, j, \dots$ が入っている

選択肢 $i$ がネスト $k$ に属しているとする...

一般的なNLの $P_i$ 導出

$$P_i = \frac{y_i}{\mu G} \frac{\partial G}{\partial y_i} = \frac{\exp(\mu_k V_i) \sum_{j \in B_l} (\exp(\mu_k V_j))^{\frac{\mu}{\mu_k} - 1}}{\sum_{l=1}^K \left( \sum_{j \in B_l} \exp(\mu_l V_j) \right)^{\frac{\mu}{\mu_l}}}$$

# 3章 各モデルの特徴

配布資料にて解説

# 4章 スケールパラメータについて

配布資料にて解説