

Daly, A., Bierlaire, M., A general and operational representation of Generalized Extreme Value models, Transportation Research Part B, vol.40, pp.285-305, 2006.
「GEVモデルの一般的表現」

植村 恵里

1. GEVモデルとは？

GEVモデル

- McFadden(1978)が導出したモデル系
- ランダム効用理論に由来するモデル系の全体を定義したもの
- 例えばMNL, NL, CNL等を含む

μ -GEV関数が満たすべき性質

1. 全ての y に対して, $G(y) \geq 0$ が成り立つ.
2. G 関数は, μ 次 $G(\lambda y) = \lambda^\mu G(y)$, for $\lambda > 0$
3. 任意の $y_i \rightarrow \infty$ のとき G の極限は $+\infty$
4. y_i の任意の k 個の組み合わせについての G の偏微分は k が奇数の時, 非負, 偶数のとき, 非正.

$$(-1)^k D_{\mathcal{X}}(y) \leq 0 \quad \forall y \in \mathbb{R}_+^J,$$

$$\text{where } \mathcal{X} = \{i_1, \dots, i_k\} \subseteq \mathcal{J}$$

$$D_{\mathcal{X}}(y) = \frac{\partial^k G}{\partial y_{i_1} \dots \partial y_{i_k}}(y).$$

1. GEVモデルとは？： μ -GEV関数

- これら4つの性質を満たす G 関数を用いると、選択確率は以下の式で表される。

$$P(i|C) = \frac{y_i \frac{\partial G}{\partial y_i}(y_1, \dots, y_J)}{\mu G(y_1, \dots, y_J)} \quad \dots(1)$$

(J : 選択肢数, $y_i = e^{V_i}$, V_i : 効用関数の確定項, G : μ -GEV関数)

Ex. MNLの場合

G 関数を $G = \sum_{j=1}^J y_j$ ($y_i = e^{V_i}$) と定義する。これは前述の4つの項目をみたとす。よってこの場合の選択確率は、(1)式より、

これら4つの性質を満たす G 関数を用いると、選択確率は以下の式で表される。

(J : 選択肢数, $y_i = e^{V_i}$, V_i : 効用関数の確定項, G : μ -GEV関数)

Ex. MNLの場合
 G 関数を $G = \sum_{j=1}^J y_j$ ($y_i = e^{V_i}$) と定義する。これは前述の4つの項目をみたとす。よってこの場合の選択確率は、(1)式より、

$$= \frac{y_i \frac{\partial G}{\partial y_i}}{G} = \frac{e^{V_i}}{\sum_{j=1}^J e^{V_j}}$$

$$= \frac{y_i \frac{\partial G}{\partial y_i}}{G} = \frac{e^{V_i}}{\sum_{j=1}^J e^{V_j}}$$



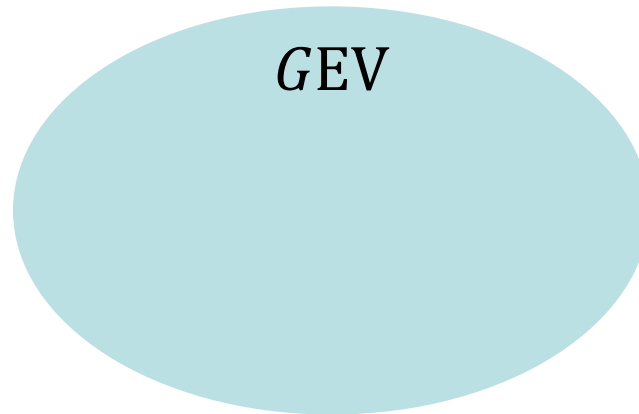
ロジットモデル
の選択確率

1. GEVモデルとは？

MNL

NL

CNL



MNL, NL, CNL等のランダム効用最大化理論に基づいたモデルが、4条件を満たすG関数によって定義づけられるということはわかった。

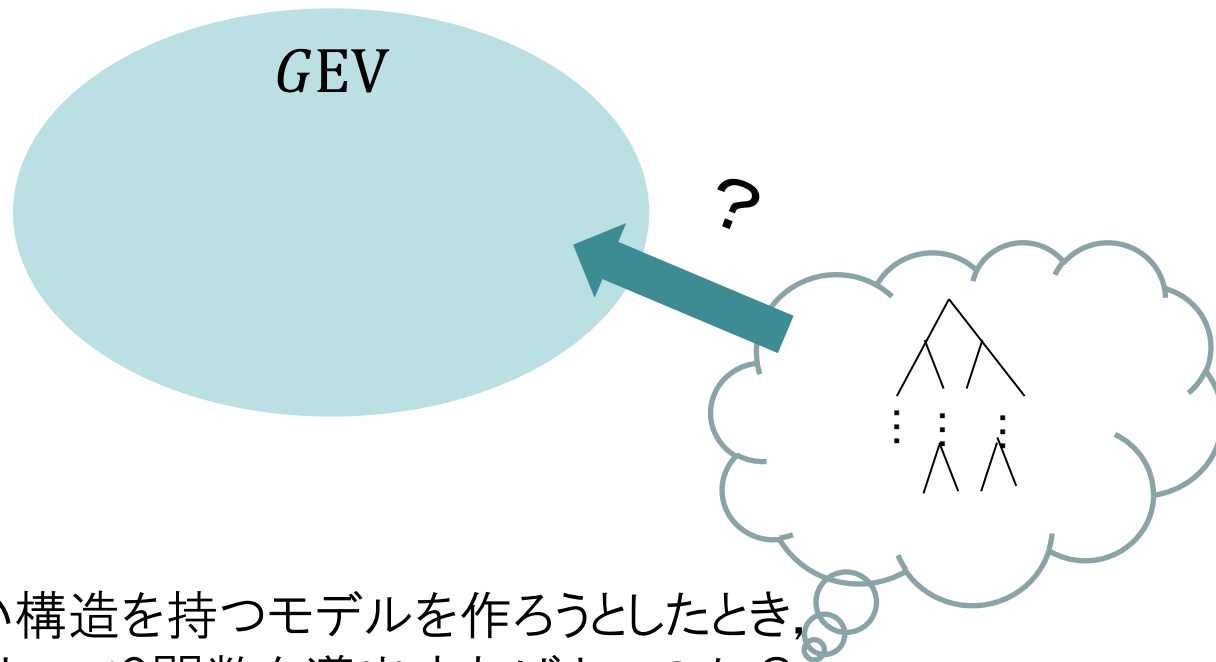
しかし・・・

1. GEVモデルとは？

MNL

NL

CNL



新しい構造を持つモデルを作ろうとしたとき、
どうやってG関数を導出すればよいのか？

2. 本研究の目的

目的

- ・ GEVモデルを一般化し, 発展可能な表現を提案する
 - 新しいGEVモデルの発展に向けた一般的な理論的基礎の提案
 - **GEV-inheritanceの証明**を用いて新しいGEVモデルの一般化が可能に
 - **GEV-network表現**により, 直感的に複雑な相関構造の記述が可能

3. GEV-inheritanceの証明

他のGEV関数から、新しいGEV関数を得られることを理論的に証明する。

- STEP1 : GEV関数の線形結合によるGEV-inheritance
- STEP2 : GEV関数を乗じることによるGEV-inheritance
- STEP3 : これらを組み合わせたmain GEV-inheritance

STEP 1

G^i が μ -GEV関数であるとき、線形結合した

$$G(y) = \sum_{i=1}^p \alpha_i G^i([y]_i)$$

も、 μ -GEV関数となる($\alpha_i > 0, i = 1, \dots, p.$)

($[y]_i$: p 個の部分空間から成る \mathbb{R}^{J_i} における y の射影)

(証明: GEV関数が満たすべき4つの性質は、明らかに $\alpha_i > 0$ によって満たされる)

3. GEV-inheritanceの証明

STEP 2

G が μ -GEV関数であるとき、 G^β は、 $(\mu\beta)$ -GEV関数となる。 $(0 < \beta \leq 1)$

証明:

1. G^β は明らかに非負
2. G が μ -homogeneityであるとき、 $G(\lambda y)^\beta = (\lambda^\mu G(y))^\beta = \lambda^{\mu\beta} G(y)^\beta$ それゆえ、 G^β は $\mu\beta$ -homogeneity
3. Limit propertyは、 $\beta > 0$ で満たされる
4. 偏微分の妥当性(帰納法を用いて証明可能:本論文のAppendix参照)

3. GEV-inheritanceの証明

STEP1・STEP2を用いると,

STEP 3

G^i が μ_i -GEV関数であるとき,

$$G = \sum_{i=1}^P \alpha_i G^i ([y]_i)^{\mu/\mu_i}$$

は, μ -GEV関数となる. ($\alpha_i > 0, 0 < \mu \leq \mu_i$)


が導ける.

→他のGEV関数から, 新しいGEV関数が得られることがわかる.

4. GEV network

GEVネットワーク

- (N, E) :有限の非空有向グラフ(N :ノード集合, E : アーク(リンク)の集合)
- $Arc(i, j)$: 非負パラメータ $\alpha_{ij} > 0$ を持つ
- ネットワークは閉路(circuit)を持たない
- ノード部分集合
 - R :predecessor(先行者)を持たない集合:root
 - C :successor(後続者)を持たないノードの集合: choice set
 - その他: nest




4. GEV network

定理

「後続点を持つ任意の v_i について、

GEVネットワークのノード v_i における G 関数 G^i は $\mu_i - GEV$ 関数

$$G^i(y_i) = \sum_{v_j \in S(v_i)} \alpha_{ij} G^j(y)^{\frac{\mu_i}{\mu_j}}$$



であり、後続点を持たない(= *choice set*である) v_i における G 関数 G^i は

$$G^i(y_i) = y^{\mu_i}$$

である」ことが、帰納法により証明できる。(本文参照)

そのため、GEVネットワークの任意のノードにおいて、選択確率が(1)式で与えられるGEVモデルが適用できる。


$$P(i|C) = \frac{y_i \frac{\partial G}{\partial y_i}(y_1, \dots, y_J)}{\mu G(y_1, \dots, y_J)} \quad \dots(1)$$

このモデルは McFadden の GEV 理論、及び、効用最大化に従っている。

4. GEV network

- ・ ネットワークにおける必要条件(有限で空ではなく, 閉路をもたない)は, 容易に確認される事項
- ・ →モデラーがすべきは, モデルの相関構造を適切に表現するようなネットワーク構造をデザインすること.
- ・ ネットワーク表現は, GEV-inheritance理論を用いて増殖させることで, 常にGEVモデルを生み出すことができる.

5. 具体例



- ・ クロスネストモデルは、以下の式で表されるG関数に由来することが、Ben-Akiva and Bierlaire(1999)で証明されている。

$$G(y_1, \dots, y_J) = \sum_{m=1}^M \left(\sum_{j \in C} \alpha_{jm} y_j^{\mu_m} \right)^{\mu / \mu_m} .$$

- ・ これが、GEVネットワークから求まることを示す。


5. 具体例

$$G(y) = \sum_{m=1}^M (G^m(y))^{\mu/\mu_m} \quad \bar{U} = \frac{\gamma}{\mu} + \frac{1}{\mu} \log \sum_{m=1}^M e^{\mu(\bar{U}_m - \frac{\gamma}{\mu_m})} \quad P(m) = \frac{(\sum_{i \in \mathcal{C}} \alpha_{im} e^{\mu_m V_i})^{\mu/\mu_m}}{\sum_{n=1}^M (\sum_{i \in \mathcal{C}} \alpha_{in} e^{\mu_n V_i})^{\mu/\mu_n}}$$

$$= \sum_{m=1}^M \left(\sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m} \right)^{\mu/\mu_m}$$

$$G^m(y) = \sum_{j \in \mathcal{C}} \alpha_{jm} (G^j(y))^{\mu_m/\mu_j} \quad \bar{U}_m = \frac{\gamma}{\mu_m} + \frac{1}{\mu_m} \log \sum_{j \in \mathcal{C}} \alpha_{jm} e^{\mu_m V_j} \quad P_m(i) = \frac{\alpha_{im} e^{\mu_m V_i}}{\sum_{j \in \mathcal{C}} \alpha_{jm} e^{\mu_m V_j}}$$

$$= \sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m}$$




$$G^i(y) = y_i^{\mu_i} \quad \bar{U}_i = V_i + \frac{\gamma}{\mu_i} \quad P_i(k) = \begin{cases} 1 & \text{if } i = k \\ 0 & \text{otherwise} \end{cases}$$

Choice set におけるG関数・期待最大効用・選択確率

5. 具体例

$$G(y) = \sum_{m=1}^M (G^m(y))^{\mu/\mu_m} \quad \bar{U} = \frac{\gamma}{\mu} + \frac{1}{\mu} \log \sum_{m=1}^M e^{\mu(\bar{U}_m - \frac{\gamma}{\mu_m})} \quad P(m) = \frac{(\sum_{i \in \mathcal{C}} \alpha_{im} e^{\mu_m V_i})^{\mu/\mu_m}}{\sum_{n=1}^M (\sum_{i \in \mathcal{C}} \alpha_{in} e^{\mu_n V_i})^{\mu/\mu_n}}$$

$$= \sum_{m=1}^M \left(\sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m} \right)^{\mu/\mu_m}$$



5. 具体例

$$G(y) = \sum_{m=1}^M (G^m(y))^{\mu/\mu_m} = \sum_{m=1}^M \left(\sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m} \right)^{\mu/\mu_m}$$


$$\bar{U} = \frac{\gamma}{\mu} + \frac{1}{\mu} \log \sum_{m=1}^M e^{\mu(\bar{U}_m - \frac{\gamma}{\mu_m})} \quad P(m) = \frac{(\sum_{i \in \mathcal{C}} \alpha_{im} e^{\mu_m V_i})^{\mu/\mu_m}}{\sum_{n=1}^M (\sum_{i \in \mathcal{C}} \alpha_{in} e^{\mu_n V_i})^{\mu/\mu_n}}$$

rootにおけるG関数・期待最大効用・選択確率

$$G^m(y) = \sum_{j \in \mathcal{C}} \alpha_{jm} (G^j(y))^{\mu_m/\mu_j} \quad \bar{U}_m = \frac{\gamma}{\mu_m} + \frac{1}{\mu_m} \log \sum_{j \in \mathcal{C}} \alpha_{jm} e^{\mu_m V_j} \quad P_m(i) = \frac{\alpha_{im} e^{\mu_m V_i}}{\sum_{j \in \mathcal{C}} \alpha_{jm} e^{\mu_m V_j}}$$

$$= \sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m}$$

$$G^i(y) = y_i^{\mu_i} \quad \bar{U}_i = V_i + \frac{\gamma}{\mu_i} \quad P_i(k) = \begin{cases} 1 & \text{if } i = k \\ 0 & \text{otherwise} \end{cases}$$



$$G(y_1, \dots, y_J) = \sum_{m=1}^M \left(\sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m} \right)^{\mu/\mu_m} \quad \text{が得られる}$$

6. まとめ

- ・ 本論文のポイント
 - GEV-inheritance 定理の証明と
 - GEV-network 表現

- ・ GEVモデルをより一般化することで、直感的な構造に従ったネットワークをつくりだす自由を与えた.