

A general and operational representation of Generalized Extreme Value models

Daly, A., Bierlaire, M., 2006.

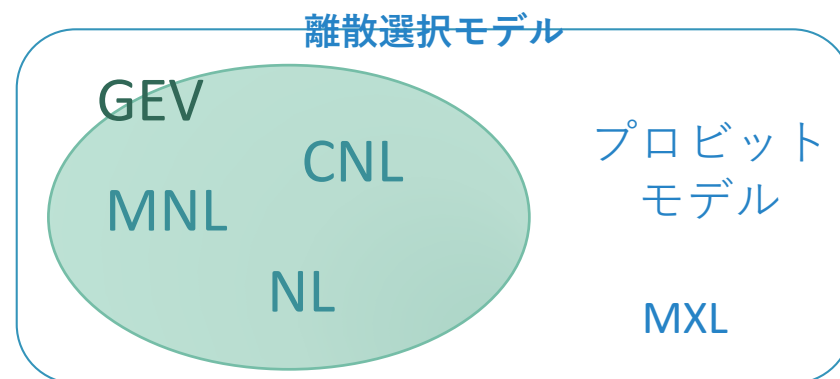
Transportation Research Part B, 40(4), 285-305.

2019/06/07 理論談話会 B4 高谷和弘

はじめに

- GEV(Generalized Extreme Value, 一般化極値)モデル

- ✓ McFadden(1978)が初出
- ✓ 様々な離散選択モデルがすべてGEVモデルとして一般化して定義
- ✓ ランダム効用理論と矛盾しない



(補足)

- 離散選択モデル
 - ランダム効用理論に基づき、「最も効用の高い選択肢を1つだけ選ぶ」として離散的な選択を表現したモデル。プロビットモデル、ロジットモデルなど。
- ランダム効用理論
 - 選択肢の持つ効用は確率的に変動すると考える理論。効用を観測可能な変数により説明可能な「確定項」と、観測不可能な個人の選好等に依存する「誤差項(確率項)」の和として表す。

$$U_j = V_j + \varepsilon_j$$

GEVモデルの特徴

長所

- ✓ Closed-formのため、計算が単純
- ✓ GEV関数(: 個人が享受する全効用を反映した関数)の扱いが平易、理論的に観測可能
- ✓ 交通行動分析との親和性
- ✓ モデルの混合がしやすい

短所

- ✓ GEV関数の仮定が複雑
→ GEVモデルの例がわずかしき提示されていない
- ✓ 個別の事例に対しGEVモデルを新たに構築する手法が確立されていない

過去の成果

- ✓ Daly(2001) : RNEVモデルによるCNLモデルの多重ネストへの一般化
- ✓ Bierlaire(2002) : NLモデルにおけるツリーをネットワーク表現として拡張・一般化したnetwork-GEVモデル
- ✓ McFadden(1978, 1981) : GEVモデルにおけるcross-nestingについて示唆
- ✓ Daly & Zachary(1978) : multi-levelのツリー構造

本論文の構成

もくじ

1. Introduction
2. The GEV model
3. GEV-inheritance
4. GEV network
5. Demand responses and elasticities
6. Specific instances
7. Estimation
8. Conclusions and future research

本論文における目標

- 直観的にGEVモデルを生成する手法の確立
 - ✓ GEV-inheritance(継承) : 既存のGEVモデルから新規のGEVモデルを生成
 - ✓ GEVネットワーク : 選択枝間の複雑な相関構造の表現
→ ネットワークに基づき帰納的かつシンプルに定式化
- GEVモデル体系の一般化とその厳密な証明
 - ✓ 過去の研究ではされていない
 - ✓ 今後追加で証明する必要がなくなる

GEVモデルの立式

(McFadden, 1978も参照)

- 選択肢集合 C から選択肢 i を選ぶ確率;

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

J : 選択肢の数, $y_i = \exp V_i$: 選択肢 i の効用確定項,
 $G(y_1, \dots, y_J)$: μ -GEV関数

- 期待最大効用

$$\bar{U} = \frac{\log G(y) + \gamma}{\mu}$$

γ : Euler定数 (実際の計算上は省略されることも)

- 選択確率と期待最大効用の関係式

$$P(i|C) = \frac{\partial \bar{U}}{\partial V_i}$$

GEVモデルの立式

(McFadden, 1978も参照)

- GEV関数 G は以下の4つの性質を満たす

1. $G(y) \geq 0, \forall y \in \mathbb{R}_+$

2. G は μ 次同次、すなわち $G(\lambda y) = \lambda^\mu G(y), \forall \lambda > 0$

3. 各選択肢 $i = 1, \dots, J$ に対し

$$\lim_{y_i \rightarrow +\infty} G(y_1, \dots, y_i, \dots, y_J) = +\infty$$

4. (GEV-differentiable) 異なる y による k 階偏微分が

k : 奇数 \Rightarrow 非負, k : 偶数 \Rightarrow 非正

すなわち

$$i_1, \dots, i_k \in \mathcal{J} = \{1, \dots, J\} \text{ に対し}$$

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

ここで

$$\mathcal{K} = i_1, \dots, i_k \in \mathcal{J}, D_{\mathcal{K}}(y) = \frac{\partial^k G}{\partial y_{i_1} \cdots \partial y_{i_k}}(y)$$

↑条件1,2,3に比べて成立の確認が難しい...

(補足)GEVモデルの例

- MNL(Multinomial logit)の場合

$$G(y) = \sum_{i \in C} y_i = \sum_{i \in C} \exp V_i$$

1. $\exp V_i > 0$ より $G(y) > 0$
2. $G(\lambda y) = \sum \lambda y_i = \lambda \sum y_i = \lambda G(y)$
3. $y_i \rightarrow \infty$ のとき $G(y) \rightarrow \infty$
4. $\frac{\partial G}{\partial y_i} = 1 > 0$, 2階以上の偏微分はすべて0

⇒ $G(y)$ はGEV関数で、選択肢 i の選択確率は

$$P(i|C) = \frac{y_i \frac{\partial G}{\partial y_i}}{G} = \frac{\exp V_i}{\sum_{j \in C} \exp V_j}$$

- 既存のGEVモデルから新しいGEVモデルを生成することが可能であることを証明する
- = 新しく定義した関数 G がGEV関数であることを示す

定理1. $\mathbb{R}^{J_i} : \mathbb{R}^J$ の部分空間, $[y]_i : \forall y \in \mathbb{R}^J$ の \mathbb{R}^{J_i} への射影,
 $G^i : \mathbb{R}^{J_i} \rightarrow \mathbb{R} : \mu$ -GEV関数 ($i = 1, \dots, p$)

のとき、 $\alpha_i > 0$ ($i = 1, \dots, p$) ならば

$$G : \mathbb{R}_+^J \rightarrow \mathbb{R} : y \mapsto G(y) = \sum_{i=1}^p \alpha_i G^i([y]_i)$$

も μ -GEV関数である。

系2. G に対する期待最大効用は $\bar{U} = \frac{\log \sum_{i=1}^p \alpha_i \exp(\mu \bar{U}_i)}{\mu}$

系3. G に対する選択肢 k の選択確率式は

$$P(k) = \sum_{i=1}^p \frac{\alpha_i \exp(\mu \bar{U}_i)}{\sum_{j=1}^p \alpha_j \exp(\mu \bar{U}_j)} P_i(k)$$

定理4. $G : \mathbb{R}_+^J \rightarrow \mathbb{R} : \mu$ -GEV関数, $0 < \beta \leq 1$

$\Rightarrow G^\beta : (\mu\beta)$ -GEV関数

系5. G^β に対する期待最大効用は $\bar{U}^* = \bar{U} + \frac{\gamma}{\mu} \left(\frac{1}{\beta} - 1 \right)$

系6. G^β に対する選択肢 k の選択確率は、 G に対する場合と不変。

定理4の証明： G^β がGEV関数の4つの性質を満たすことを確認する。

1. $G \geq 0$ より自明に $G^\beta \geq 0$
2. $\lambda > 0$ に対し $G(\lambda y) = \lambda^\mu G(y)$ より

$$G(\lambda y)^\beta = \lambda^\mu G(y)^\beta = \lambda^{\mu\beta} G(y)^\beta$$

3. $\beta > 0$ より自明。
4. 帰納法で示す。順次微分し符号を確かめる。複雑なので割愛。

● GEV関数 G は以下の4つの性質を満たす

1. $G(y) \geq 0, \forall y \in \mathbb{R}_+$
2. G は μ 次同次、すなわち $G(\lambda y) = \lambda^\mu G(y), \forall \lambda > 0$
3. 各選択肢 $i=1, \dots, J$ に対し

$$\lim_{y_i \rightarrow +\infty} G(y_1, \dots, y_i, \dots, y_J) = +\infty$$

4. (GEV-differentiable) 異なる y による k 回偏微分が
 k : 奇数 \Rightarrow 非負, k : 偶数 \Rightarrow 非正

すなわち

$$i_1, \dots, i_k \in \mathcal{J} = \{1, \dots, J\} \text{ に対し}$$

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

ここで $\mathcal{K} = i_1, \dots, i_k \in \mathcal{J}, D_{\mathcal{K}}(y) = \frac{\partial^k G}{\partial y_{i_1} \cdots \partial y_{i_k}}(y)$

- 定理1,4を組み合わせると、次が得られる;

定理7. (GEV-inheritance)

$\mathbb{R}^{J_i} : \mathbb{R}^J$ の部分空間, $[y]_i : \forall y \in \mathbb{R}^J$ の \mathbb{R}^{J_i} への射影,

$G^i : \mathbb{R}_+^{J_i} \rightarrow \mathbb{R} : \mu_i$ -GEV関数 ($i = 1, \dots, p$)

のとき、 $\alpha_i > 0$, $0 < \mu \leq \mu_i$ ($i = 1, \dots, p$) のもとで

$$G : \mathbb{R}_+^J \rightarrow \mathbb{R} : y \mapsto G(y) = \sum_{i=1}^p \alpha_i \{G^i([y]_i)\}^{\mu/\mu_i}$$

は μ -GEV関数である。

系8. G に対する期待最大効用は

$$\bar{U} = \frac{\gamma + \log \sum_{i=1}^p \alpha_i \exp \left[\mu \left(\bar{U}_i - \frac{\gamma}{\mu_i} \right) \right]}{\mu}$$

系9. G に対する選択肢 k の選択確率は

$$P(k) = \sum_{i=1}^p \Omega_i P_i(k), \quad \Omega_i = \frac{\alpha_i \exp \left[\mu \left(\bar{U}_i - \frac{\gamma}{\mu_i} \right) \right]}{\sum_{j=1}^p \alpha_j \exp \left[\mu \left(\bar{U}_j - \frac{\gamma}{\mu_j} \right) \right]}$$

GEVネットワーク

- 選択肢どうしの結びつき (=効用の相関) をネットワーク構造で表現する

(N, E) : 有向グラフ

N : ノードの集合

E : エッジの集合


$\alpha_{ij} (> 0)$: エッジ (i, j) に対応するパラメータ

\mathcal{R} : 先頭のノード (=root) の集合

\mathcal{C} : 末端のノード (=選択肢) J 個の集合

$\mu_i (> 0)$: ノード $v_i \in N$ に対応するパラメータ


- GEVネットワークの条件：閉じた環（周回）がない



ネットワークによるGEVモデルの生成

- GEV関数：末端から順番に帰納的に定義

$$\begin{cases} v_i \in \mathcal{C} \text{ のとき} & G^i : \mathbb{R}_+ \rightarrow \mathbb{R}_+ : G^i(y_i) = y_i^{\mu_i} \quad (\mu_i > 0) \\ v_i \notin \mathcal{C} \text{ のとき} & \mathbb{R}_+^{J_i} = \text{span}_{v_j \in S(v_i)} \langle \mathbb{R}_+^{J_j} \rangle, \\ & G^i : \mathbb{R}_+^{J_i} \rightarrow \mathbb{R}_+ : G^i(y) = \sum_{v_j \in S(v_i)} \alpha_j [G^j(y)]^{\mu_i / \mu_j} \end{cases} \quad S(v_i)$$



作成した関数 G^i は本当にGEV関数なのか？ \Rightarrow 定理10

定理10. $\forall v_j \notin \mathcal{C}, \mu_j \leq \mu_k \quad \forall k \text{ s.t. } v_k \in S(v_j)$

のとき、ノード v_i に対応する関数 G^i は μ_i -GEV 関数である。

証明：帰納法。末端から順に定理7を適用する。

- $v_i \in \mathcal{C}$ のとき

$$\bar{U}_i = V_i + \frac{\gamma}{\mu_i}$$


$$P_i(k) = \begin{cases} 1 & (\text{if } i = k) \\ 0 & (\text{otherwise}) \end{cases}$$



経路に沿って帰納的に条件付き確率をかけ合わせることで、選択確率式が得られる

$$P_j(i) = \sum_{\mathcal{K}_{ij}} \prod_{k=1}^{K_{ij}} P_k(k+1) = \sum_{\mathcal{K}_{ij}} \prod_{k=1}^{K_{ij}} \frac{\partial \bar{U}_k}{\partial \bar{U}_{k+1}}$$

GEVネットワークの例



③最上端(ルート)での各選択枝の選択確率が求まる

$$P(k) = \sum_{m=1}^M P(m)P_m(k)$$

ネストの選択確率 × 条件付き選択確率



②下から順に
GEV関数を定義し、期待最大効用と選択確率を導出



①末端の選択枝ノードについて、GEV関数を定義

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

選択確率の計算手順

(前頁の例の場合)

- 各選択肢*i*について

$$G^i(y) = y_i^{\mu_i} \quad \bar{U}_i = V_i + \frac{\gamma}{\mu_i}$$

$$P_i(k) = \begin{cases} 1 & (\text{if } i = k) \\ 0 & (\text{otherwise}) \end{cases}$$

- 各ネスト*m*について

$$G^m(y) = \sum_{j \in \mathcal{C}} \alpha_{jm} [G^j(y)]^{\mu_m / \mu_j} \quad \bar{U}_m = \frac{\gamma}{\mu_m} + \frac{1}{\mu_m} \log \sum_{j \in \mathcal{C}} \alpha_{jm} \exp(\mu_m V_j)$$

$$= \sum_{j \in \mathcal{C}} \alpha_{jm} y_j^{\mu_m} \quad P_m(i) = \frac{\alpha_{im} \exp(\mu_m V_i)}{\sum_{j \in \mathcal{C}} \alpha_{jm} \exp(\mu_m V_j)}$$

- ルートについて

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

$$\bar{U} = \frac{\gamma}{\mu} + \frac{1}{\mu} \log \sum_{m=1}^M \exp \left[\mu \left(\bar{U}_m - \frac{\gamma}{\mu_m} \right) \right] = \frac{\gamma}{\mu} + \frac{1}{\mu} \log \sum_{m=1}^M \left[\sum_{i \in \mathcal{C}} \alpha_{im} \exp(\mu_m V_i) \right]^{\mu / \mu_m}$$

$$P(k) = \sum_{m=1}^M P(m) P_m(k) = \sum_{m=1}^M \frac{[\sum_{i \in \mathcal{C}} \alpha_{im} \exp(\mu_m V_i)]^{\mu / \mu_m}}{\sum_{n=1}^M [\sum_{i \in \mathcal{C}} \alpha_{in} \exp(\mu_n V_i)]^{\mu / \mu_n}} \frac{\alpha_{km} \exp(\mu_m V_k)}{\sum_{j \in \mathcal{C}} \alpha_{jm} \exp(\mu_m V_j)}$$

需要応答性・弾力性

- 選択肢 j の説明変数 x_j に対する選択肢 i の選択確率の弾力性

$$\eta_{i,x_j} = \frac{P(i) \text{ の変化率}}{x_j \text{ の変化率}} = \frac{\partial P(i)}{\partial x_j} \frac{x_j}{P(i)}$$

説明変数の
パラメータ

$$= \frac{\partial P(i)}{\partial V_j} \frac{\partial V_j}{\partial x_j} \frac{x_j}{P(i)} = \frac{\partial P(i)}{\partial V_j} \frac{\beta_{x_j} x_j}{P(i)}$$

- 添字が混在していてわかりにくい

→効用 V_j の変化に対する応答性 $\partial P(i)/\partial V_j$ に着目すると明快

- 定理7(GEV-inheritance)により、需要応答性は次のように導出される。

定理12/系13. 需要応答性は次式により継承される。

$$\frac{\partial P(i)}{\partial V_l} = \sum_{i=1}^p \left\{ \Omega_i \frac{\partial P_i(k)}{\partial V_l} + \mu P_i(k) \Omega_i \left(P_i(l) - \sum_{m=1}^M P_m(l) \Omega_m \right) \right\}$$

ただし

$$\Omega_i = T_i/S, \quad S = \sum_{j=1}^p T_j, \quad T_i = \alpha_i \exp \left[\mu \left(\bar{U}_i - \frac{\gamma}{\mu_i} \right) \right]$$

パラメータ推定

- パラメータ推定は、最尤推定法（=尤度最大化）で行う
 - ✓ Pythonの無料パッケージ「BIOGEME」が利用可能
- network-GEVモデルによる選択確率は、tree (nested) logit model での選択確率と同一
 - ✓ tree logitの推定コードを少し書き換えるだけでnetwork-GEVの推定が可能に

注意点

- パラメータ値が $\alpha_{ij} = 0$ となるエッジ (i, j) は必ずネットワークから取り除く
- パラメータ μ ：比 μ_i/μ_j のみが選択確率に影響
 - ✓ →正規化（例えば最上端か末端で $\mu = 1$ ）
- パラメータ α ： α を定数倍するのは、 G が定数倍されるのと同じでこのとき確率の値は変動しない
 - ✓ →正規化（下式、参考：CNL）

$$\sum_i \delta_{ij} \alpha_{ij}^{\mu_i/\mu_j} = 1, \forall j \notin \mathcal{R}, \delta_{ij} = \begin{cases} 1 & \text{if } j \in S(i) \\ 0 & \text{otherwise} \end{cases}$$

結論

- 本論文の成果は、**GEV-inheritance**の証明と**GEV**ネットワーク表現の導入。
 - ✓ 選択枝どうしの相関について、直観的解釈に基づき**GEV**モデルを設計することが可能に。
- ネットワーク構造によるシンプルな記述、**pythonBIOGEME**等で容易に推定が可能という点で操作性◎
- 新しい**GEV**モデルを開発する際、その都度難解な数学的証明を行う必要がなくなった。
- 自由にネットワーク構造をつくることのできるため、モデル設計の自由度が高い。

(Appendix) 定理4.の詳しい証明

- GEV関数の4つの性質のうち、4番目 (GEV-differentiability) について関数 G^β が満たすことを示す。

✓ 性質1,2,3は簡単に示せる。

✓ $D_{\mathcal{K}}^*(y) = \frac{\partial^k}{\partial y_1 \dots \partial y_k} G(y)^\beta$ の符号を調べる。

- 次頁の補題14,15を示すことで導く。

✓ 補題14: k 階偏微分 $D_{\mathcal{K}}^*(y)$ を導出。帰納法による。添字集合 $\{1, \dots, k\}$ の「分割」について注意が必要。

✓ 補題15: 補題14で示された k 階偏微分の各項について、もう1度微分すると必ず符号が逆になる。

定理4. $G: \mathbb{R}_+^J \rightarrow \mathbb{R}$: μ -GEV関数, $0 < \beta \leq 1$
 $\Rightarrow G^\beta$ は $(\mu\beta)$ -GEV関数。

- GEV関数 G は以下の4つの性質を満たす

1. $G(y) \geq 0, \forall y \in \mathbb{R}_+$

2. G は μ 次同次、すなわち $G(\lambda y) = \lambda^\mu G(y), \forall \lambda > 0$

3. 各選択肢 $i=1, \dots, J$ に対し

$$\lim_{y_i \rightarrow +\infty} G(y_1, \dots, y_i, \dots, y_J) = +\infty$$

4. (GEV-differentiable) 異なる y による k 回偏微分が

k : 奇数 \Rightarrow 非負, k : 偶数 \Rightarrow 非正

すなわち

$i_1, \dots, i_k \in \mathcal{J} = \{1, \dots, J\}$ に対し

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

ここで $\mathcal{K} = i_1, \dots, i_k \in \mathcal{J}, D_{\mathcal{K}}(y) = \frac{\partial^k G}{\partial y_{i_1} \dots \partial y_{i_k}}(y)$

(Appendix) 定理4.の詳しい証明

補題14. \mathcal{P}_k : 添字集合 $\{1, \dots, k\}$ の分割の集合,

$P \in \mathcal{P}_k$: p 個の添字から構成される分割, R : r 個の添字を含む集合,

$$S^p(y) := G(y)^{\beta-p} \prod_{i=0}^{p-1} (\beta - i), D_R := \frac{\partial^r G(y)}{(\partial y_i)_{i \in R}}$$

このとき、 $G^* := G^\beta$ に対して k 階偏微分 $D_{\mathcal{K}}^*(y)$ が次式で導かれる。

$$D_{\mathcal{K}}^*(y) = \frac{\partial^k}{\partial y_1 \dots \partial y_k} G(y)^\beta = \sum_{P \in \mathcal{P}_k} S^p \left(\prod_{R \in P} D_R \right) \quad (55)$$

補題15. 任意の k について、

$0 < \beta \leq 1$, $P \in \mathcal{P}_{\mathcal{K}}$: $p(\geq 1)$ 個の添字から構成される分割
のとき、補題14で導いた(55)式中の項

$$S^p(y) \prod_{R \in P} D_R$$

の符号と、その導関数

$$\frac{\partial}{\partial y_{k+1}} \left(S^p(y) \prod_{R \in P} D_R \right)$$

の符号は逆である。

(Appendix) 補題15の証明

$$\frac{\partial}{\partial y_{k+1}} \left(S^p(y) \prod_{R \in P} D_R \right) = \left(\frac{\partial}{\partial y_{k+1}} S^p(y) \right) \prod_{R \in P} D_R + S^p(y) \left(\frac{\partial}{\partial y_{k+1}} \prod_{R \in P} D_R \right)$$

- 右辺第1項について

$$S^p(y) = \underbrace{G(y)^{\beta-p}}_{\geq 0} \underbrace{\prod_{i=0}^{p-1} (\beta - i)}_{\geq 0}, \quad \frac{\partial}{\partial y_{k+1}} S^p(y) = \underbrace{\frac{\partial G}{\partial y_{k+1}}}_{\geq 0} \underbrace{\prod_{i=0}^{p-1} (\beta - i) (\beta - p)}_{\geq 0} \underbrace{G(y)^{\beta-(p+1)}}_{\geq 0}$$

この符号は必ず逆 ($\because \beta - p \leq 0$)

- 右辺第2項は、 D_R の定義より

$$D_R := \frac{\partial^r G(y)}{(\partial y_i)_{i \in R}}$$

→ GEV関数 $G(y)$ が性質4(GEV-differentiable)を満たしていることから、 D_R とその偏導関数 $\frac{\partial}{\partial y_{k+1}} D_R$ の符号は逆になる。

4. (GEV-differentiable) 異なる y による k 回偏微分が
 k : 奇数 \Rightarrow 非負, k : 偶数 \Rightarrow 非正
 すなわち
 $i_1, \dots, i_k \in \mathcal{J} = \{1, \dots, J\}$ に対し
 $(-1)^k D_{\mathcal{K}}(y) \leq 0, \forall y \in \mathbb{R}_+$
 ここで $\mathcal{K} = i_1, \dots, i_k \in \mathcal{J}, D_{\mathcal{K}}(y) = \frac{\partial^k G}{\partial y_{i_1} \dots \partial y_{i_k}}(y)$

(Appendix) 補題14の証明の指針

- 1階偏導関数

$$D_{\{1\}}^*(y) = \frac{\partial}{\partial y_1} G(y)^\beta = \beta G(y)^{\beta-1} \frac{\partial G}{\partial y_1}$$

- 2階偏導関数

$$D_{\{1,2\}}^*(y) = \frac{\partial^2}{\partial y_1 \partial y_2} G(y)^\beta = \beta(\beta-1)G(y)^{\beta-2} \frac{\partial G}{\partial y_1} \frac{\partial G}{\partial y_2} + \beta G(y)^{\beta-1} \frac{\partial^2 G}{\partial y_1 \partial y_2}$$

- 3階偏導関数

$$\begin{aligned} D_{\{1,2,3\}}^*(y) &= \frac{\partial^3}{\partial y_1 \partial y_2 \partial y_3} G(y)^\beta \\ &= \beta(\beta-1)(\beta-2)G(y)^{\beta-3} \frac{\partial G}{\partial y_1} \frac{\partial G}{\partial y_2} \frac{\partial G}{\partial y_3} \\ &\quad + \beta(\beta-1)G(y)^{\beta-1} \left(\frac{\partial G}{\partial y_1} \frac{\partial^2 G}{\partial y_2 \partial y_3} + \frac{\partial G}{\partial y_2} \frac{\partial^2 G}{\partial y_3 \partial y_1} + \frac{\partial G}{\partial y_3} \frac{\partial^2 G}{\partial y_1 \partial y_2} \right) \\ &\quad + \beta G(y)^{\beta-1} \frac{\partial^3 G}{\partial y_1 \partial y_2 \partial y_3} \end{aligned}$$

集合{1, 2, 3}に対する
「分割」を考える

(Appendix) 集合の分割

- Indexの集合 $\{1, \dots, k\}$ に対する分割は次のように再帰的に定義される。

$$\mathcal{P}_0 = \emptyset, \mathcal{P}_1 = \{\{\{1\}\}\}, \mathcal{P}_k = \bigcup_{i=1}^p \mathcal{P}_i^k \left(\mathcal{P}_i^k = \bigcup_{j=1}^{n_i} R_j^i, R_j^i \subseteq \{1, \dots, k\} \right)$$

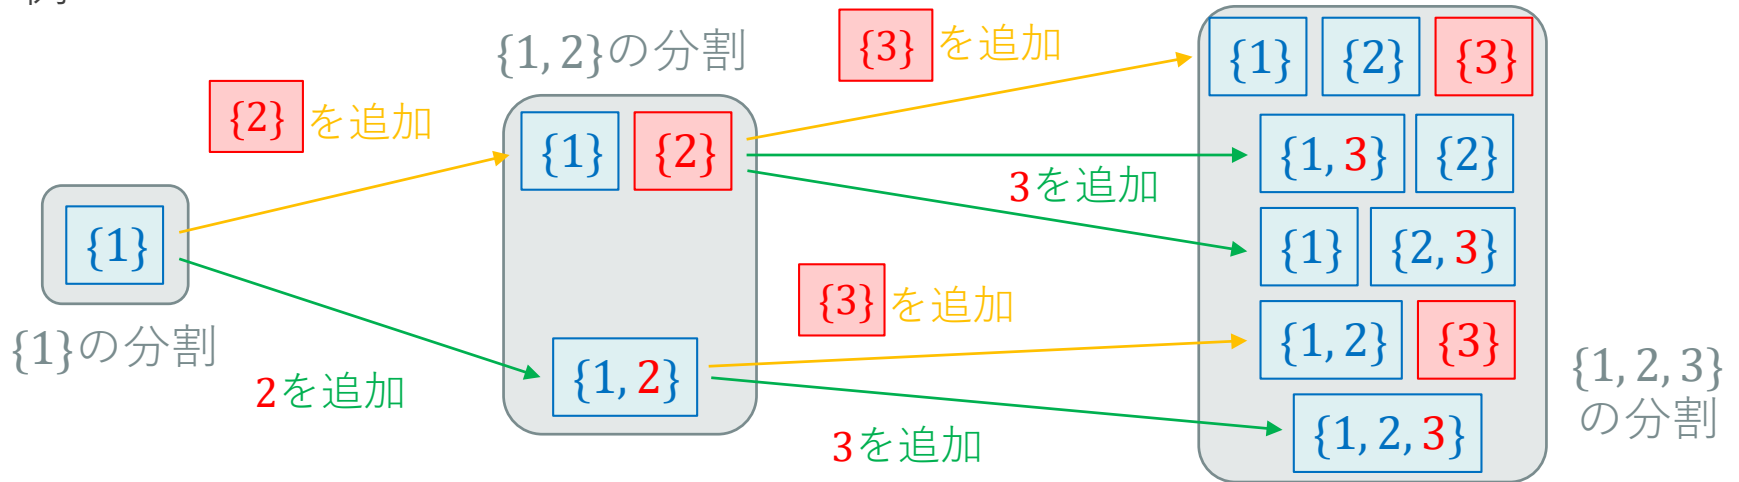
- \mathcal{P}_k から \mathcal{P}_{k+1} を構成する

✓ 1つは、単集合 $\{\{k+1\}\}$ を \mathcal{P}_i^k に加える

✓ 他すべてに対しては、分割された各添字集合 R_j^i を、一度に1つだけ $R_j^i \cup \{k+1\}$ に置き換える

$$\mathcal{P}_{k+1} = \bigcup_{i=1}^p \left[(\mathcal{P}_i^k \cup \{\{k+1\}\}) \cup \bigcup_{l=1}^{n_i} \mathcal{P}_{i,l}^{k+1} \right] \quad (71) \quad \left(\mathcal{P}_{i,l}^{k+1} = \{R_l^i \cup \{k+1\}\} \cup \bigcup_{j=1, j \neq l}^{n_i} R_j^i \quad (72) \right)$$

- 例



(Appendix) 補題14の証明

- 帰納法。 $k = 1$ で成立。
- 帰納法の仮定より

$$\begin{aligned}
 \frac{\partial^k}{\partial y_1 \dots \partial y_{k+1}} G(y)^\beta &= \frac{\partial}{\partial y_{k+1}} \left(\frac{\partial^k}{\partial y_1 \dots \partial y_k} G(y)^\beta \right) = \frac{\partial}{\partial y_{k+1}} \left[\sum_{P \in \mathcal{P}_k} S^p \prod_{R \in P} D_R \right] \\
 &= \sum_{P \in \mathcal{P}_k} \left[\left(\frac{\partial}{\partial y_{k+1}} S^p \right) \prod_{R \in P} D_R + S^p \left(\frac{\partial}{\partial y_{k+1}} \prod_{R \in P} D_R \right) \right] \\
 &= \sum_{P \in \mathcal{P}_k} \left[\left(S^{p+1} \frac{\partial G}{\partial y_{k+1}} \right) \prod_{R \in P} D_R + S^p \sum_{R \in P} D_{R \cup \{k+1\}} \prod_{T \in P, T \neq R} D_T \right]
 \end{aligned}$$

- (71)(72)式の分割の定義から

$$\begin{aligned}
 \frac{\partial^k}{\partial y_1 \dots \partial y_{k+1}} G(y)^\beta &= \sum_{i=1}^p \left[S^{p+1} \prod_{R \in P \cup \{k+1\}} D_R + \sum_{l=1}^{n_i} S^p \prod_{R \in P_{i,l}^{k+1}} D_R \right] = \sum_{P \in \mathcal{P}_{k+1}} S^p \prod_{R \in P} D_R \\
 \mathcal{P}_{k+1} &= \bigcup_{i=1}^p \left[(P_i^k \cup \{k+1\}) \cup \bigcup_{l=1}^{n_i} P_{i,l}^{k+1} \right] \quad (71) \quad \left(P_{i,l}^{k+1} = \{R_l^i \cup \{k+1\}\} \cup \bigcup_{j=1, j \neq l}^{n_i} R_j^i \right) \quad (72)
 \end{aligned}$$

- k で成立するとき、 $k + 1$ でも成立することが示せた。