

ロジットモデルの一般 化とネットワーク分析

中山晶一郎

(金沢大学 環境デザイン学系)



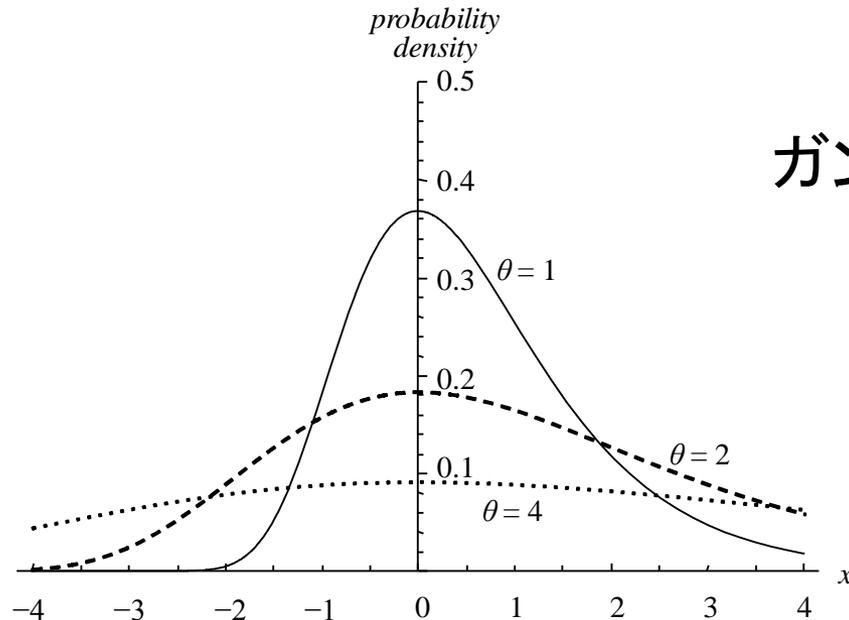
誤差項のガンベル分布

形状が右裾が長いものに限られる

定義域が $-\infty$ から $+\infty$ (通常は非負の変数が多い)

定量的計算には形状の自由度が高いほうがよい

$U = -\alpha c + \varepsilon = -(\alpha c - \varepsilon)$ では負側の裾が長くなる



ガンベル分布の累積分布関数:

$$F(x) = \exp \left[-\exp \left(-\frac{x - \mu}{\theta} \right) \right]$$



ガンベル分布と極値分布

極値分布は3種類

- ガンベル型 → ガンベル分布
- フレシエ型
- ワイブル型

一般化極値分布

(GEV: generalized extreme value distribution)

紛らわしいが、ネスティッドロジットなどが導出できる
GEVとは別もの



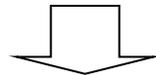
一般化極値分布

一般化極値分布
の累積分布関数

$$\tilde{G}(x) = \exp \left\{ - \left[1 + \gamma \left(\frac{x - \mu}{\theta} \right) \right]^{-\frac{1}{\gamma}} \right\}$$

$\exp(x) = \lim_{\gamma \rightarrow 0} (1 + \gamma x)^{\frac{1}{\gamma}}$ であるため、上式は

$\gamma \rightarrow 0$ の時、 $\tilde{G}(x) = \exp \left\{ - \exp \left[- \left(\frac{x - \mu}{\theta} \right) \right] \right\}$

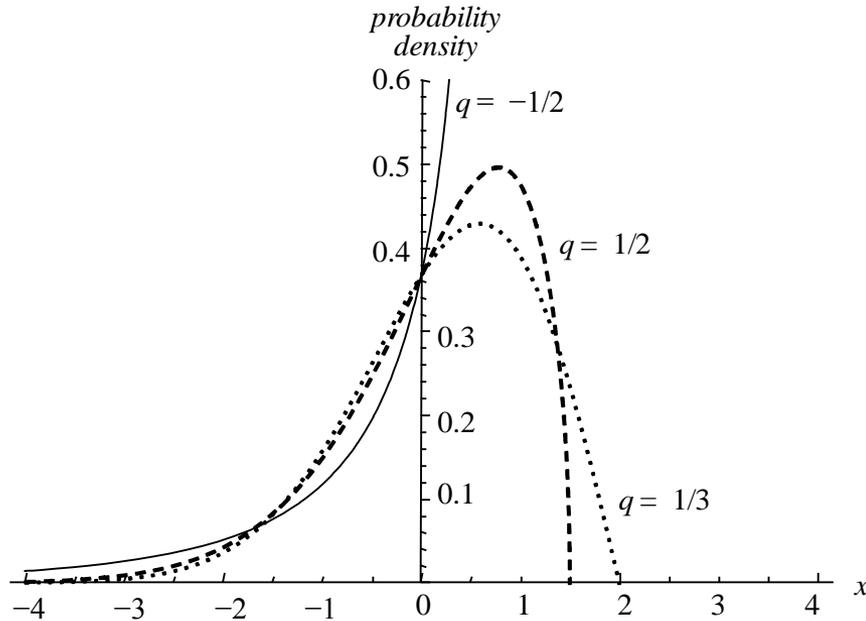


ガンベル分布(二重指数分布)

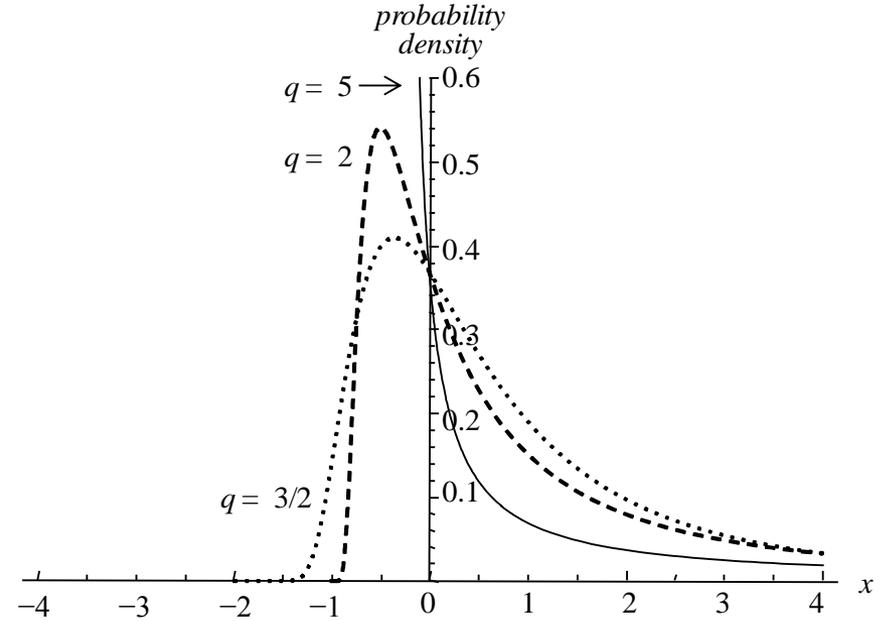


一般化極値分布の形状

$q < 1$ の時



$q > 1$ の時





一般化とq-関数

一般化:

通常の数指数関数をq-指数関数に置き換える

q-指数関数:

$$\exp_q(x) := [1 + (1 - q)x]^{1/(1-q)} \xrightarrow{q \rightarrow 1} \exp_1(x) = \exp(x)$$

$$\because \exp(x) = \lim_{\gamma \rightarrow 0} (1 + \gamma x)^{1/\gamma}$$

q-対数関数:

$$\ln_q(x) := \frac{x^{1-q} - 1}{1 - q} \xrightarrow{q \rightarrow 1} \ln_1(x) = \ln(x)$$



一般化極値分布の分布関数

$$\tilde{G}(x) = \exp \left\{ - \left[1 + \gamma \left(\frac{x - \mu}{\theta} \right) \right]^{-\frac{1}{\gamma}} \right\}$$

$\gamma = q - 1$, $\mu = v$, $\theta = s - (1 - q)v$ とすると,

$$G(x) = \exp \left[- \exp_q \left(- \frac{x - v}{s - (1 - q)v} \right) \right]$$

$$= \exp \left\{ - \left[1 + (1 - q) \left(- \frac{x - v}{s - (1 - q)v} \right) \right]^{\frac{1}{1 - q}} \right\}$$



選択肢 i の効用の分布関数

$$G_i(x) = \exp \left[- \exp_q \left(- \frac{x - v_i}{s - (1 - q)v_i} \right) \right]$$

$$\hat{v}_i := \frac{v_i}{s - (1 - q)v_i} \quad \text{とすると,}$$

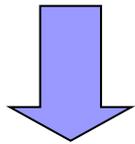
$$G_i(x) = \exp \left[- \exp_q(\hat{v}_i) \exp_q \left(- \frac{x}{s} \right) \right] \quad \text{となる}$$



一般化ロジットの導出

累積分布関数 $G_i(x)$ とそれを微分した確率密度関数 $g_i(x) = dG_i(x)/dx$ を用いると、選択肢 i が選択される確率は

$$p_i = \int_{x \in \Omega} G_1(x) \cdots G_{i-1}(x) g_i(x) G_{i+1}(x) \cdots G_I(x) dx$$



$$p_i = \frac{\exp_q(\hat{v}_i)}{\sum_{i'=1}^I \exp_q(\hat{v}_{i'})}$$



導出準備

$$\text{効用} : U_i = v_i + \varepsilon_i \quad (1)$$

U_i : 選択肢 i の効用

v_i : 選択肢 i の確定効用

ε_i : 確率項

選択肢1が選択されるのは、選択肢1の効用 U_1 が他の選択肢の効用 U_2, U_3, \dots よりも大きい場合 ($U_1 > U_2, U_1 > U_3, \dots$)

よって、選択肢1を選択する確率は

$$p_1 = \Pr[U_1 > U_2] \Pr[U_1 > U_3] \dots \Pr[U_1 > U_I] \quad (2)$$

ε_i が従う確率分布の確率密度関数を $f_i(x_i)$ 、累積分布関数を $F_i(x_i)$ とすると、

$$p_1 = \int_{x \in \Omega} g_1(x) G_2(x) \dots G_I(x) dx \quad (3)$$



一般化ロジットの導出1

$G_i(x)$: 一般化極値分布の累積分布関数

$g_i(x) = dG_i(x)/dx$: 確率密度関数

後の置換積分のため, $z := \exp_q\left(-\frac{x}{s}\right)$ とすると,

$$g_1(x) = \frac{d}{dx} G_1(x) = -\exp_q(\hat{v}_1) G_1(x) \frac{dz}{dx}$$

$$\therefore G_i(x) = \exp\left[-\exp_q(\hat{v}_i) \exp_q\left(-\frac{x}{s}\right)\right]$$

これを式(3)に代入すると,

$$p_1 = -\exp_q(\hat{v}_1) \int_{z \in \hat{\Omega}} G_1(x) G_2(x) \cdots G_I(x) dz$$



一般化ロジットの導出2

$$\sigma = \sum_{i=1}^I \exp_q(\hat{v}_i) \text{ とすると,}$$

$$\prod_{i=1}^I G_i(x) = \exp \left[-\sigma \exp_q \left(-\frac{x}{s} \right) \right] = \exp(-\sigma z) \text{ であるので,}$$

$$\begin{aligned} p_1 &= -\exp_q(\hat{v}_1) \int_{z \in \hat{\Omega}} \exp(-\sigma z) dz \\ &= \frac{\exp_q(\hat{v}_1)}{\sigma} \left[\exp(-\sigma z) \right]_{\infty}^0 \\ &= \frac{\exp_q(\hat{v}_1)}{\sum_{i=1}^I \exp_q(\hat{v}_i)} \end{aligned}$$



ツァリス一般化ロジット

ツァリス一般化ロジット

通常ロジット

$$p_i = \frac{\exp_q(\hat{v}_i)}{\sum_{i'=1}^I \exp_q(\hat{v}_{i'})}$$

$$\xrightarrow[s=1]{q \rightarrow 1}$$

← 一般化

$$p_i = \frac{\exp(v_i)}{\sum_{i'=1}^I \exp(v_{i'})}$$



ワイビット

誤差項がワイブル分布の離散選択モデル

Castillo, E. et al. (2008) Closed form expressions for choice probabilities in the Weibull case. *Transportation Research*, 42B, 373–80

$$p_i = \frac{v_i^\alpha}{\sum_{i'=1}^I v_{i'}^\alpha}$$

かつて、上式を用いた配分は時間比配分と呼ばれていた。



ワイビットの含有

$$\begin{aligned}\exp_q(\hat{v}) &= [1 + (1-q)\hat{v}]^{\frac{1}{1-q}} \\ &= \left[(1-q) \left(\hat{v} + \frac{1}{1-q} \right) \right]^{\frac{1}{1-q}} \\ &= (1-q)^{\frac{1}{1-q}} \left(\hat{v} + \frac{1}{1-q} \right)^{\frac{1}{1-q}} \\ p_i &= \frac{\exp_q(\hat{v}_i)}{\sum_{i'=1}^I \exp_q(\hat{v}_{i'})} = \frac{\left(\hat{v}_i + \frac{1}{1-q} \right)^{\frac{1}{1-q}}}{\sum_{i'=1}^I \left(\hat{v}_{i'} + \frac{1}{1-q} \right)^{\frac{1}{1-q}}}\end{aligned}$$

一般化ロジットモデルはワイビットも含んでいる



ツァリス・エントロピー

$$S_q(\mathbf{p}) = -\frac{1 - \sum_{i=1}^I p_i^q}{1 - q} = -\sum_{i=1}^I p_i^q \ln_q(p_i)$$

↓ $q \rightarrow 1$

$$-\sum_{i=1}^I p_i \ln(p_i)$$

シャノンエントロピー



ツァリス一般化ロジット配分

$$f_{ij} = d_i \frac{\exp_q(-\theta c_{ij})}{\sum_{j'=1}^{J_i} \exp_q(-\theta c_{ij'})}$$

f_{ij} : ODペア i の経路 j の経路交通量

c_{ij} : ODペア i の経路 j の旅行時間

d_i : ODペア i の交通需要

θ : パラメータ



ツァリス一般化ロジット配分の最適化問題

旅行時間が固定 (non-congested network)

$$\min_{\mathbf{p}} \cdot \sum_{i=1}^I \sum_{j=1}^{J_i} p_{ij}^q c_{ij} - \frac{1}{\theta} \sum_{i=1}^I S_q(\mathbf{p}_i)$$

$$s.t. \sum_{i=1}^I p_i = 1$$

$$p_{ij} = \frac{f_{ij}}{d_i}$$

渋滞ネットワーク場合は、上の問題を緩和問題とする緩和法で解くことが可能



ロジットモデルのツァリス的一般化

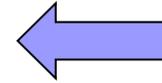
離散選択誤差項

ボルツマン統計

ガンベル分布

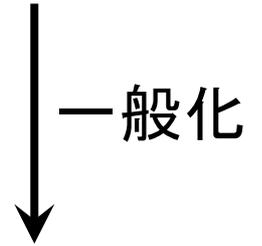
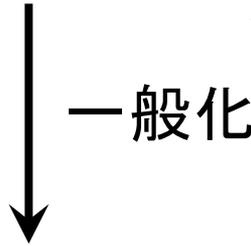
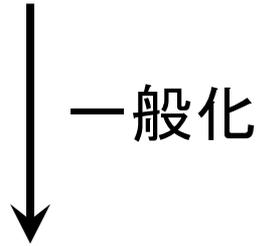


ロジットモデル
ボルツマン分布
(カノニカル分布)



シャノン
エントロピー

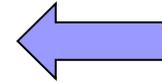
$$p_i = \frac{\exp(-\beta E_i)}{\sum_{i=1}^I \exp(-\beta E_i)}$$



一般化
極値分布



ツァリス一般化
ロジットモデル



ツァリス
エントロピー

ツァリス統計



まとめ

- ガンベル分布を一般化極値分布に一般化
- 一般化ロジットモデルの導出
- それはツァリス・エントロピーの最大化からも導出される
- 一般化ロジット配分の解法を提案