

魅力度モデルと集計データによる交差弾力性について

いくつかの背景知識

マーケティング変数の弾力性

目的変数（売上数量など） Q における X の点弾力性を e_Q とする。 e_Q は以下のように定義される。

$$e_Q = \frac{Q \text{の相対的変化}}{X \text{の相対的変化}} = \frac{\frac{\Delta Q}{Q}}{\frac{\Delta X}{X}} = \frac{\partial Q}{\partial X} \cdot \frac{X}{Q}$$

ここで、

$$\frac{d(\log X)}{dX} = \frac{1}{X}$$

または、

$$d(\log X) = \frac{dX}{X} = X \text{の相対的変化}$$

なので、

$$e_Q = \frac{Q \text{の相対的変化}}{X \text{の相対的変化}} = \frac{d(\log Q)}{d(\log X)}$$

でもある。

e_Q に以下の通減型対数線形モデルを代入する。

$$Q = e^\alpha \prod_{i=1}^k X_i^{\beta_i} \varepsilon$$

$$\log Q = \alpha + \sum_{i=1}^k \beta_i \log(X_i) + \log \varepsilon$$

$i=1$ として、

$$Q = e^\alpha X^\beta \varepsilon$$

$$e_Q = \frac{\partial Q}{\partial X} \cdot \frac{X}{Y} = e^\alpha \beta X^{\beta-1} \varepsilon \cdot \frac{X}{e^\alpha X^\beta \varepsilon} = \beta$$

よって通減型対数線形モデルのパラメータは独立変数の目的変数に対する点弾力性となる。

確率分布の基礎

幾何分布

成功確率が p のベルヌーイ試行において、はじめて成功する時点を表す確率変数 X の従う分布は以下の幾何分布で表される。

$$P(X = k) = p(1 - p)^{k-1}, k = 1, 2, \dots$$

$$X \sim \text{Geo}(p)$$

ベルヌーイ試行の独立同一性から、幾何分布は無記憶性を持つ。

$$P(X - x > y | X > x) = P(X > y)$$

指数分布

幾何分布を連続形にした分布。密度関数は、

$$f(x) = \lambda e^{-\lambda x}, x \geq 0$$

分布関数は、

$$F(x) = 1 - e^{-\lambda x}, x \geq 0$$

$$T \sim \text{Exp}(\lambda)$$

である。

(注) 連続的な確率変数の確率分布において以下の関係がある。

$$P(a \leq X \leq b) = \int_a^b f(x) \quad \text{この時 } f(x) \text{ を密度関数と呼ぶ。}$$

$$F(x) = \int_{-\infty}^x f(y) dy = P(X \leq x), x \in \mathfrak{R}$$

この時 $F(x)$ を分布関数と呼ぶ。「 X が x 以下

$$\frac{d}{dx} F(x) = f(x)$$

の確率」である。

指数分布は無記憶性を持つ唯一の連続関数である。

密度関数を $f(t)$ 、分布関数を $F(t)$ とする時、

$$h(x) = \frac{f(t)}{1 - F(x)} \approx \frac{1}{dt} P(t < T \leq t + dt | T > t)$$

をハザード率という。 $\text{Exp}(\lambda)$ のハザード率は一定である。 $(h(x) = \lambda)$

ロジスティック分布

以下の分布関数が与えられるとき、ロジスティック分布に従うという。

$$F(x) = \frac{1}{1 + e^{-a(x-b)}}, x \in \mathfrak{R}, a > 0$$

$$X \sim L(a, b)$$

密度関数は、

$$f(x) = \frac{ae^{-a(x-b)}}{1 + e^{-a(x-b)}} = aF(x)(1 - F(x)), x \in \mathfrak{R}, a > 0 \text{ で成長曲線である。}$$

極値分布

X_1, X_2, \dots を同一の分布関数 $G(x)$ を持つ確率変数の列とし、

$$Y_n = \max\{X_1, X_2, \dots, X_n\} - \theta \log n$$

とおく。 Y_n の分布関数を $F_n(x)$ とすれば、

$$\begin{aligned} F_n(x) &= P(\max\{X_1, X_2, \dots, X_n\} \leq x + \theta \log n) \\ &= [G(x + \theta \log n)]^n \end{aligned}$$

たとえば $X_i \sim \text{Exp}(1/\theta)$ の時、

$$F_n(x) = \left(1 - e^{-(x + \theta \log n)/\theta}\right)^n = \left(1 - \frac{e^{-x/\theta}}{n}\right)^n$$

これは、 $n \rightarrow \infty$ の時 $\exp\{-e^{-x/\theta}\}$ に収束する。確率変数の最大値におけるこのような極限分布を極値分布という。極値分布には次の三種類がある。

タイプ I : 二重指数分布

タイプ II : フレッシュェ分布

タイプ III : ワイブル分布

二重指数分布

分布関数は、

$$F(x) = \exp\{-e^{-\lambda(x-\mu)}\}, x \in \mathfrak{R}, \lambda > 0$$

密度関数は、

$$f(x) = \lambda \exp\{-\lambda(x-\mu) - e^{-\lambda(x-\mu)}\}, x \in \mathfrak{R}, \lambda > 0$$

これを、 $X \sim DE(\lambda, \mu)$ と書く。

MCI モデル

以下のように定式化される。

$$A_i = \exp\{\alpha_i\} \prod_{k=1}^K X_{ki}^{\beta_k} \varepsilon_i$$

$$S_i = \frac{A_i}{\sum_{j=1}^n A_j}$$

対数中央化すると線形になる。まず両辺の対数を取る。

$$\log S_i = \alpha_i + \sum_{k=1}^K \beta_k \log X_{ki} + \log \varepsilon_i - \log \left\{ \sum_{j=1}^n \left(\exp\{\alpha_j\} \prod_{k=1}^K X_{kj}^{\beta_k} \varepsilon_j \right) \right\}$$

i に関し合計し、 n で割ると、

$$\log \tilde{S} = \bar{\alpha} + \sum_{k=1}^K \beta_k \log \tilde{X}_k + \log \tilde{\varepsilon} - \log \left\{ \sum_{j=1}^n \left(\exp\{\alpha_j\} \prod_{k=1}^K X_{kj}^{\beta_k} \varepsilon_j \right) \right\}$$

ここで $\tilde{\cdot}$ のあるものは幾何平均、 $\bar{\cdot}$ のつくものは平均。上の式から下の式を引くと、以下が得られる。

$$\log \left(\frac{S_i}{\tilde{S}} \right) = \alpha_i - \bar{\alpha} + \sum_{k=1}^K \beta_k \log \left(\frac{X_{ki}}{\tilde{X}_k} \right) + \log \left(\frac{\varepsilon_i}{\tilde{\varepsilon}} \right)$$

なお、 $\exp(\alpha_i) = a_i$ とおくと

$$\log \left(\frac{S_i}{\tilde{S}} \right) = \log \left(\frac{a_i}{\tilde{a}} \right) + \sum_{k=1}^K \beta_k \log \left(\frac{X_{ki}}{\tilde{X}_k} \right) + \log \left(\frac{\varepsilon_i}{\tilde{\varepsilon}} \right) \text{ が得られる。 (?)}$$

MNL モデル

以下のように定式化される。

$$A_i = \exp \left\{ \alpha_i + \sum_{k=1}^K \beta_k X_{ki} + \varepsilon_i \right\}$$

$$S_i = \frac{A_i}{\sum_{j=1}^n A_j}$$

対数中央化で以下のように線形式となる。

$$\log \left(\frac{S_i}{\tilde{S}} \right) = \alpha_i - \bar{\alpha} + \sum_{k=1}^K \beta_k (X_{ki} - \bar{X}_k) + \varepsilon_i - \bar{\varepsilon}$$

