

応用システム工学
第5回 指数型分布族と
一般化線形モデル
平成21年7月03日

指数型分布族の対数尤度関数 最尤推定の準備

- 指数型分布族の確率密度関数

$$f(y, \theta) = \exp[a(y)b(\theta) + c(\theta) + d(y)]$$

- 指数型分布族の尤度関数

$$L(\theta, y) = \exp[a(y)b(\theta) + c(\theta) + d(y)]$$

- 指数型分布族の対数尤度関数

$$l(\theta, y) = \log L(\theta, y) = a(y)b(\theta) + c(\theta) + d(y)$$

- スコア統計量

– 対数尤度関数の θ に関する微分

- パラメータの推測に利用できる → 最尤推定

指数型分布族の対数尤度関数

- スコア統計量 U
$$U(\theta, y) = \frac{d}{d\theta} l(\theta, y) = a(y)b'(\theta) + c'(\theta)$$

– U は y に依存するので確率変数

$$U(Y) = a(Y)b'(\theta) + c'(\theta)$$

– U の期待値は a の期待値で表される

- a は Y に依存する確率変数

$$E[U(Y)] = E[a(Y)b'(\theta) + c'(\theta)]$$

指数型分布族の対数尤度関数

- スコア統計量Uの期待値

$$\begin{aligned} E[U(Y)] &= E[a(Y)b'(\theta) + c'(\theta)] \\ &= b'(\theta)E[a(Y)] + c'(\theta) \\ &= b'(\theta) \left\{ -\frac{c'(\theta)}{b'(\theta)} \right\} + c'(\theta) \\ &= -c'(\theta) + c'(\theta) \\ &= 0 \end{aligned}$$

- スコア統計量の期待値は0となる

指数型分布族の対数尤度関数

- スコア統計量 U の分散→情報量を表す
 - スコア統計量は確率変数 $a(Y)$ の線形変換

$$U(Y) = a(Y)b'(\theta) + c'(\theta)$$

$$\mathfrak{J} = \text{var}[U(Y)] = \text{var}[a(Y)b'(\theta) + c'(\theta)] = b'(\theta)^2 \text{var}[a(Y)]$$

$$\text{var}[U(Y)] = b'(\theta)^2 \text{var}[a(Y)]$$

$$= b'(\theta)^2 \frac{b''(\theta)c'(\theta) - c''(\theta)b'(\theta)}{b'(\theta)^3}$$

$$= \frac{b''(\theta)c'(\theta) - c''(\theta)b'(\theta)}{b'(\theta)}$$

指数型分布族の対数尤度関数

- スコア統計量のほかの性質1

$$\begin{aligned}\text{var}[U(Y)] &= E[U(Y)^2] - E[U(Y)]^2 \\ &= E[U(Y)^2] \\ &- \because E[U(Y)] = 0\end{aligned}$$

- スコア統計量のほかの性質2

$$\begin{aligned}\frac{d}{d\theta} U(Y) &= U'(Y) = \frac{d}{d\theta} [a(Y)b'(\theta) + c'(\theta)] \\ &= a(Y)b''(\theta) + c''(\theta)\end{aligned}$$

指数型分布族の対数尤度関数

- スコア統計量のほかの性質

$$\begin{aligned} E[U'(Y)] &= E[a(Y)b''(\theta) + c''(\theta)] \\ &= b''(\theta)E[a(Y)] + c''(\theta) \\ &= b''(\theta) \left\{ -\frac{c'(\theta)}{b'(\theta)} \right\} + c''(\theta) \\ &= \frac{-b''(\theta)c'(\theta) + b'(\theta)c''(\theta)}{b'(\theta)} \\ &= -\text{var}[U(Y)] = -\mathfrak{J} \end{aligned}$$

最尤推定で利用

一般化線形モデル

一般化線形モデル

- 指数型分布族の分布を持つ
- 独立な確率変数 Y_1, \dots, Y_N の集合の条件
 - 条件1: 各確率変数 Y_i の分布は正準形 ($a(y)=y$) で一つのパラメータ θ_i に依存

$$f(y_i; \theta_i) = \exp[y_i b(\theta_i) + c(\theta_i) + d(y_i)]$$

- 条件2: 全ての確率変数 Y_i の分布は同じ型

一般化線形モデル

- 確率変数 Y_1, \dots, Y_N の同時確率密度関数

$$\begin{aligned} f(y_1, \dots, y_N; \theta_1, \dots, \theta_N) &= \prod_{i=1}^N \exp[y_i b(\theta_i) + c(\theta_i) + d(y_i)] \\ &= \exp \left[\sum_{i=1}^N y_i b(\theta_i) + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(\theta_i) \right] \end{aligned}$$

一般化線形モデル

- 少数のパラメータでモデルを表現
 - 確率変数 Y_i の期待値 μ_i がパラメータ β_1, \dots, β_p ($p < N$)の関数として表される
 - 説明変数ベクトル $x_i^T = [x_{i1}, \dots, x_{ip}]$
 - ダミー変数
 - パラメータベクトル $\beta^T = [\beta_1, \dots, \beta_p]$
 - 単調かつ微分可能な連結関数

$$g(\mu_i) = x_i^T \beta$$

一般化線形モデル

- モデルの構成

- 確率変数 Y_1, \dots, Y_N (指数型分布族)

- パラメータベクトル β の集合と説明変数の行列

$$\beta = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} \quad X = \begin{bmatrix} x_1^T \\ \vdots \\ x_N^T \end{bmatrix} = \begin{bmatrix} x_{11} & \cdots & x_{1p} \\ \vdots & & \vdots \\ x_{N1} & \cdots & x_{Np} \end{bmatrix}$$

- 単調な連結関数 g $g(\mu_i) = x_i^T \beta$ $\mu_i = E[Y_i]$

パラメータの推定

- 推定法
 - 最尤推定法 → これをする
 - 最小二乗法
 - その他
- 一般化線形モデル
 - 最尤法によるパラメータの点推定・区間推定
 - 数値解析
 - 収束計算(ニュートンラプソン法)

一般化線形モデルの最尤推定

- 一般化線形モデルの確率変数 Y_1, \dots, Y_N

- 期待値 $\mu_i = E[Y_i]$

- 連結関数 $g(\mu_i) = x_i^T \beta = \eta_i$

- 確率変数に関するパラメータ β の推定

- 各確率変数に対する対数尤度関数

$$l_i = y_i b(\theta_i) + c(\theta_i) + d(y_i)$$

$$\text{var}[Y_i] = \frac{b''(\theta_i)c'(\theta_i) - c''(\theta_i)b'(\theta_i)}{b'(\theta_i)^3}$$

$$E[Y_i] = \mu_i = -\frac{c'(\theta_i)}{b'(\theta_i)}$$

一般化線形モデルの最尤推定

- 全ての確率変数に対する対数尤度関数

$$l = \sum_{i=1}^N l_i = \sum_{i=1}^N y_i b(\theta_i) + \sum_{i=1}^N c(\theta_i) + \sum_{i=1}^N d(\theta_i)$$

– 対数尤度関数を最大化するパラメータ β

- スコア関数 $U(\beta) = 0$

$$\frac{\partial l}{\partial \beta_j} = U_j = \sum_{i=1}^N \left[\frac{\partial l_i}{\partial \beta_j} \right] = \sum_{i=1}^N \left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$$

- 非線形関数の解を求める → ニュートンラプソン法

ニュートンラプソン法

- 非線形関数 y が x 軸と交わる点を求める

$$y(x) = 0$$

– 値 $x^{(m-1)}$ での関数の傾き

$$\left. \frac{dy}{dx} \right|_{x=x^{(m-1)}} = y'(x^{(m-1)}) \cong \frac{y(x^{(m)}) - y(x^{(m-1)})}{x^{(m)} - x^{(m-1)}}$$

– $y(x^{(m)}) = 0$ なら $y'(x^{(m-1)}) = \frac{0 - y(x^{(m-1)})}{x^{(m)} - x^{(m-1)}}$

- 収束するまで計算 $x^{(m)} = x^{(m-1)} - \frac{y(x^{(m-1)})}{y'(x^{(m-1)})}$
 - スコア関数の微分を求める必要有

一般化線形モデルの最尤推定

- スコア関数内微分第一項 $\left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$

$$\frac{\partial l_i}{\partial \theta_i} = \frac{\partial}{\partial \theta_i} [y_i b(\theta_i) + c(\theta_i) + d(y_i)] = y_i b'(\theta_i) + c'(\theta_i)$$

– 期待値の関係 $E[Y_i] = \mu_i = -\frac{c'(\theta_i)}{b'(\theta_i)}$

$$c'(\theta_i) = -\mu_i b'(\theta_i)$$

$$\frac{\partial l_i}{\partial \theta_i} = y_i b'(\theta_i) + c'(\theta_i) = y_i b'(\theta_i) - \mu_i b'(\theta_i) = b'(\theta_i) [y_i - \mu_i]$$

一般化線形モデルの最尤推定

- $\frac{\partial l_i}{\partial \theta_i} = y_i b'(\theta_i) + c'(\theta_i) = y_i b'(\theta_i) - \mu_i b'(\theta_i) = b'(\theta_i)[y_i - \mu_i]$
- スコア関数内微分第二項 $\left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$

$$\frac{\partial \mu_i}{\partial \theta_j} = \frac{\partial}{\partial \theta_j} \left[-\frac{c'(\theta_i)}{b'(\theta_i)} \right] = -\frac{b'(\theta_i)c''(\theta_i) - b''(\theta_i)c'(\theta_i)}{b'(\theta_i)^2}$$

– 前出の分散 $\text{var}[Y_i] = \frac{b''(\theta_i)c'(\theta_i) - c''(\theta_i)b'(\theta_i)}{b'(\theta_i)^3}$

一般化線形モデルの最尤推定

- 分散を代入

$$\begin{bmatrix} \frac{\partial l_i}{\partial \theta_i} & \frac{\partial \theta_i}{\partial \mu_i} & \frac{\partial \mu_i}{\partial \beta_j} \end{bmatrix}$$

$$\frac{\partial \mu_i}{\partial \theta_i} = b'(\theta_i) \text{var}[Y_i]$$

$$\frac{\partial \theta_i}{\partial \mu_i} = \frac{1}{\frac{\partial \mu_i}{\partial \theta_i}} = \frac{1}{b'(\theta_i) \text{var}[Y_i]}$$

一般化線形モデルの最尤推定

- スコア関数内微分第三項 $\left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$

$$\frac{\partial \mu_i}{\partial \beta_j} = \frac{\partial \mu_i}{\partial \eta_j} \frac{\partial \eta_j}{\partial \beta_j} = \frac{\partial \mu_i}{\partial \eta_j} \frac{\partial}{\partial \beta_j} [x_i^T \beta] = \frac{\partial \mu_i}{\partial \eta_j} x_{ij}$$

- スコア関数

$$\begin{aligned} U_j &= \sum_{i=1}^N \left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right] = \sum_{i=1}^N \left[b'(\theta_i) [y_i - \mu_i] \frac{1}{b'(\theta_i) \text{var}[Y_i]} \frac{\partial \mu_i}{\partial \eta_j} x_{ij} \right] \\ &= \sum_{i=1}^N \left[\frac{y_i - \mu_i}{\text{var}[Y_i]} \frac{\partial \mu_i}{\partial \eta_j} x_{ij} \right] \end{aligned}$$