

応用システム工学
第6回 指数型分布族と
一般化線形モデル
平成22年7月09日

パラメータの推定

- 一般化線形モデルのパラメータの点推定・区間推定
- 推定法
 - 最尤推定法 → これをする
 - 最小二乗法
 - その他
- 求め方
 - 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

- 独立な確率変数 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

- x_i は要素 $x_{ij}, j=1, 2, \dots, p$ のベクトル

- 各確率変数 Y_i の対数尤度関数

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

期待値・分散

$$\left\{ \begin{array}{l} \text{var}[Y_i] = \frac{b''(\theta_i)c'(\theta_i) - c''(\theta_i)b'(\theta_i)}{b'(\theta_i)^3} \\ E[Y_i] = \mu_i = -\frac{c'(\theta_i)}{b'(\theta_i)} \end{array} \right.$$

一般化線形モデルの最尤推定

- 全ての確率変数 Y_i に対する対数尤度関数

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

- 対数尤度関数を最大化するパラメータ β_j (最尤推定値)

- 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

- スコア関数内要素
微分第一項を求める $\left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$
$$\frac{\partial l_i}{\partial \theta_i} = \frac{\partial}{\partial \theta_i} [y_i b(\theta_i) + c(\theta_i) + d(y_i)] = y_i b'(\theta_i) + c'(\theta_i)$$
$$E[Y_i] = \mu_i = -\frac{c'(\theta_i)}{b'(\theta_i)}$$

– 期待値の関係を用いる $c'(\theta_i) = -\mu_i b'(\theta_i)$

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

となる

一般化線形モデルの最尤推定

- スコア関数内要素
微分第二項を求める $\left[\begin{array}{ccc} \frac{\partial l_i}{\partial \theta_i} & \frac{\partial \theta_i}{\partial \mu_i} & \frac{\partial \mu_i}{\partial \beta_j} \end{array} \right]$

$$\mu_i = -\frac{c'(\theta_i)}{b'(\theta_i)} \quad \text{より}$$

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

– 分散の別表現より

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

一般化線形モデルの最尤推定

- スコア関数ない要素
微分第二項に分散を代入 $\left[\begin{array}{ccc} \frac{\partial l_i}{\partial \theta_i} & \frac{\partial \theta_i}{\partial \mu_i} & \frac{\partial \mu_i}{\partial \beta_j} \end{array} \right]$

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

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

一般化線形モデルの最尤推定

- スコア関数内要素
微分第三項を求める $\left[\frac{\partial l_i}{\partial \theta_i} \frac{\partial \theta_i}{\partial \mu_i} \frac{\partial \mu_i}{\partial \beta_j} \right]$ 連結関数
 $x_i^T \beta = \eta_i$

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

β_j だけ残る

- スコア関数

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

一般化線形モデルの最尤推定

- スコア関数の微分

- スコア関数の微分の期待値で近似

- 情報量を利用

$$E[U'(Y)] = -\text{var}[U(Y)] = -\mathfrak{I}$$

- スコア関数 U_j の分散共分散行列を情報行列 \mathfrak{I}

- (j,k)要素

$$\mathfrak{I}_{jk} = E[U_j U_k]$$

(スコア統計量の分散は情報量 \mathfrak{I})

- 確率変数 Y_i は独立

$$E[(Y_j - \mu_j)(Y_k - \mu_k)] = 0, j \neq k$$

一般化線形モデルの最尤推定

情報行列を求める

$$\begin{aligned}\mathfrak{I}_{jk} &= E \left\{ \sum_{i=1}^N \left[\frac{y_i - \mu_i}{\text{var}[Y_i]} \frac{\partial \mu_i}{\partial \eta_i} x_{ij} \right] \sum_{l=1}^N \left[\frac{y_l - \mu_l}{\text{var}[Y_l]} \frac{\partial \mu_l}{\partial \eta_l} x_{lk} \right] \right\} \\ &= \sum_{i=1}^N \left\{ \frac{E[(y_i - \mu_i)^2]}{\text{var}[Y_i]^2} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ij} x_{ik} \right\}\end{aligned}$$

$$E[(y_i - \mu_i)^2] = \text{var}[Y_i] \quad \text{より}$$

$$\mathfrak{I}_{jk} = \sum_{i=1}^N \left[\frac{x_{ij} x_{ik}}{\text{var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 \right] \quad \text{となる}$$

これを行列で表現すると $\mathfrak{I} = X^T w X$
できる

ただし w は
の $N \times N$ 対角行列

$$w_{ii} = \frac{1}{\text{var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2$$

最尤推定のスコア関数表現

- ニュートン・ラプソン法公式 $x^{(m)} = x^{(m-1)} - \frac{y(x^{(m-1)})}{y'(x^{(m-1)})}$

- パラメータ・スコア関数表現 $\theta^{(m)} = \theta^{(m-1)} - \frac{U^{(m-1)}}{U'^{(m-1)}}$

– U' を期待値 $E[U']$ で近似 $U' \approx E[U'(Y)] = -\mathfrak{I}$

$$\theta^{(m)} = \theta^{(m-1)} + \frac{U^{(m-1)}}{\mathfrak{I}^{(m-1)}}$$

一般化線形モデルの最尤推定

- ニュートン・ラプソン法への適用
 - パラメータベクトル**b**での表現

$$b^{(m)} = b^{(m-1)} + [\mathfrak{J}^{(m-1)}]^{-1} U^{(m-1)}$$

- ただし $b^{(m)}$ はm回目反復時におけるパラメータ $\beta_1, \beta_2, \dots, \beta_p$ の推定値ベクトル
- $U^{(m-1)}$ はスコアベクトル
- $[\mathfrak{J}^{(m-1)}]^{-1}$ は情報行列の逆行列
- 逆行列を元に戻す

$$\mathfrak{J}^{(m-1)} b^{(m)} = \mathfrak{J}^{(m-1)} b^{(m-1)} + U^{(m-1)}$$

一般化線形モデルの最尤推定

- 情報行列を代入して要素を求める
- j要素

$$\left[\mathcal{J}^{(m-1)} b^{(m-1)} + U^{(m-1)} \right]_j = \sum_{k=1}^P \sum_{i=1}^N \left[\frac{x_{ij} x_{ik}}{\text{var}[Y_i]} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 \right] b_k^{(m-1)} + \sum_{i=1}^N \left[\frac{y_i - \mu_i}{\text{var}[Y_i]} \frac{\partial \mu_i}{\partial \eta_j} x_{ij} \right]$$

まとめると $X^T W X b^{(m)} = X^T W z$ できる

$$\text{ただし } z_i = \sum_{k=1}^P x_{ij} b_k^{(m-1)} + (y_i - \mu_i) \frac{\partial \mu_i}{\partial \eta_j}$$

重み付き最小二乗の変形であり, 反復重み付最小二乗法という