

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21年7月10日

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

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

- 情報行列 \mathfrak{I} はスコア関数 U_j の分散共分散行列
 - (j,k)要素 $\mathfrak{I}_{jk} = E[U_j U_k]$
 - 確率変数は独立

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

一般化線形モデルの最尤推定

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

$$= \sum_{i=1}^N \left[\frac{E[(y_i - \mu_i)^2]}{\text{var}[Y_i]^2} \left(\frac{\partial \mu_i}{\partial \eta_i} \right)^2 x_{ij} x_{ik} \right]$$
$$E[(y_i - \mu_i)^2] = \text{var}[Y_i]$$

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

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

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

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

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

$$X^T W X b^{(m)} = X^T W z \quad z_i = \sum_{k=1}^P x_{ij} b_k^{(m-1)} + (y_i - \mu_i) \frac{\partial \mu_i}{\partial \eta_j}$$

重み付き最小二乗の変形

統計的推測

統計的推測

- 信頼区間(区間推定)
 - 検定結果:信頼区間が値を含むかどうか
 - 検定精度:信頼区間の幅
- 仮説検定
 - 関連するモデルのデータへの適合度の判定
 - 要約統計量(適合度統計量)を用いた当てはめの適合性
 - 尤度関数の最大値
 - 対数尤度関数の最大値
 - 平方和基準の最小値
 - 残差に基づく複合型の統計量

仮説検定

- 作業仮説・実験仮説を対立仮説H1
- 作業仮説を否定する仮設を帰無仮説H0
- 帰無仮説を仮説検定の対象とする。
 - 帰無仮説が棄却されると対立仮説が支持される。
 - 帰無仮説が支持される場合
 - 真に対立仮説が誤っている
 - 対立仮説は正しいが、標本の大きさが十分でなく、帰無仮説を積極的に棄却できない

仮説検定のプロセス

- モデル:帰無仮説 $H_0 \rightarrow M_0$, 対立仮説 $H_1 \rightarrow M_1$
- 適合統計量: $M_0 \rightarrow G_0$, $M_1 \rightarrow G_1$
- 適合のよさの評価: $G_1 - G_0$ または G_1/G_0
- 対立仮説 $G_1 \neq G_0$ に対する帰無仮説 $G_1 = G_0$ の検定: $G_1 - G_0$ の標本分布を評価
 - $G_1 = G_0$ が棄却されなければ H_0 は棄却されず, M_0 がより良いモデルとなる。
 - $G_1 = G_0$ が棄却されれば H_0 は棄却され, M_1 がより良いモデルとなる。

一般化線形モデルに関する標本分布

スコア統計量の標本分布

- 一般化線形モデル
 - 互いに独立な確率変数 Y_1, \dots, Y_N
 - パラメータ β
 - 期待値 $\mu_i = E[Y_i]$
 - 連結関数 $g(\mu_i) = x_i^T \beta = \eta_i$
 - スコア統計量 $U_j = \frac{\partial l}{\partial \beta_j} = \sum_{i=1}^N \left[\frac{(Y_i - \mu_i)}{\text{var}(Y_i)} x_{ij} \left(\frac{\partial \mu_i}{\partial \eta_j} \right) \right], j = 1, \dots, p$
 - スコア統計量の期待値
 - $E[Y_i] = \mu_i$ より $E[U_j] = 0, j = 1, \dots, p$

スコア統計量の標本分布

- スコア統計量の分散共分散行列 \mathfrak{I} の要素

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

- 単一のパラメータ β に対するスコア統計量の漸近標本分布

– 尤度関数

$$l = \sum l_i \quad \xleftarrow{\text{確率変数 } Y_i \text{ の関数}}$$

$$l_i = \log f(Y_i, \beta)$$

– スコア統計量

$$U = \sum U_i$$
$$l_i = \frac{\partial \log f(Y_i, \beta)}{\partial \beta}$$

スコア統計量の標本分布

- 確率変数 $Y_i, i=1, \dots, n$ が互いに独立
 - $U_i, i=1, \dots, n$ も互いに独立
 - 確率分布も同一

$$E[U] = 0, \text{var}[U] = \mathfrak{I}$$

多変量正規分布漸近する

$$\xrightarrow{} U \sim N(0, \mathfrak{I})$$

もとの標本では

$$\xrightarrow{} U^T \mathfrak{I}^{-1} U \sim \chi^2(p)$$

対数尤度関数の近似

- 統計量の漸近的な標本分布を得る

- テイラー級数展開

$$f(x) = f(t) + (x-t) \left[\frac{df}{dx} \right]_{x=t} + \frac{1}{2} (x-t)^2 \left[\frac{d^2 f}{dx^2} \right]_{x=t} + \dots$$

- 対数尤度関数。パラメータ β の推定値 b 近傍での近似

$$l(\beta) = l(b) + (\beta - b) U(b) + \frac{1}{2} (\beta - b)^2 U'(b) + \dots$$

$$\cong l(b) + (\beta - b) U(b) + \frac{1}{2} (\beta - b)^2 U'(b)$$

対数尤度関数の近似

- スコア関数($\beta = b$)

$$U(b) = \frac{dl}{d\beta}$$

- スコア関数の一回微分の期待値による近似

$$U' = \frac{d^2l}{d\beta^2} \quad E(U') = -\mathfrak{J}$$

$$l(\beta) \approx l(b) + (\beta - b)U(b) - \frac{1}{2}(\beta - b)^2 \mathfrak{J}(b)$$

対数尤度関数の近似

- パラメータベクトル β の対数尤度関数の近似

$$l(\beta) \approx l(b) + (\beta - b)U(b) - \frac{1}{2}(\beta - b)^T \mathfrak{J}(b)(\beta - b)$$

- スコア関数の泰イラ一級数近似

$$U(\beta) = U(b) + (\beta - b)U'(b) + \frac{1}{2}(\beta - b)^2 U''(b) + \dots$$

$$\begin{aligned} &\approx U(b) + (\beta - b)U'(b) \\ &= U(b) - (\beta - b)\mathfrak{J}(b) \end{aligned}$$

- ベクトルの場合 $U(\beta) \approx U(b) - \mathfrak{J}(b)(\beta - b)$

最尤推定量の標本分布

- 最尤推定量 $b = \hat{\beta}$

– 対数尤度関数を最大にする $U(b) = 0$

$$U(\beta) \cong U(b) - \mathfrak{J}(b)(\beta - b) = -\mathfrak{J}(b)(\beta - b)$$

- 情報統計量が正則なら

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

- 情報統計量が一定ならスコア関数の期待値は0より

$$E[\mathfrak{J}(b)^{-1} U(\beta)] = \mathfrak{J}(b)^{-1} E[U(\beta)] = E[-(\beta - b)] = 0$$

b と β は一致する

最尤推定量の標本分布

- 情報行列

$$\mathfrak{I} = E[UU^T]$$

- 対称性

$$(\mathfrak{I}^{-1})^T = \mathfrak{I}^{-1}$$

- 最尤推定量の分散共分散行列

$$E[(b - \beta)(b - \beta)^T] = \mathfrak{I}^{-1} E[UU^T] \mathfrak{I}^{-1} = \mathfrak{I}^{-1}$$

- ワルド統計量

- パラメータ数 p (自由度 p) のカイニ乗分布

$$(b - \beta)^T \mathfrak{I}^{-1} (b - \beta) \sim \chi^2(p)$$

対数尤度比統計量

- モデルの適切さの評価
 - 最も一般(推定されうる最大個数のパラメータを含む)モデルと比較
 - 飽和モデル, 最大モデル, フルモデル
 - 確率分布, 連結関数が同じ一般化線形モデル同士
 - N 個の観測値 $Y_i, i=1, \dots, N$ があれば, N 個の線形成分 $X_i^T \beta$ を対応させる N このパラメータでモデルを表せる
 - 推定できるパラメータの数は, 相異なる線形成分の数に等しい→繰り返し
 - » 同じ線形成分(同じ共変量)をもつ観測値では, 連続的な説明変数も同じになる

対数尤度比統計量

- 飽和モデルのパラメータ数:m
- 飽和モデルのパラメータベクトル: β_{\max}
- パラメータベクトルの最尤推定量: b_{\max}
 - 飽和モデルの尤度関数は最も大きい $L(b_{\max}; y)$
 - 関心のあるモデルの尤度関数との比でモデルの適合度を評価:尤度比

$$\lambda = \frac{L(b_{\max}; y)}{L(b; y)}$$

対数尤度比統計量

- 尤度比の対数→対数尤度関数の差

$$\log \lambda = l(b_{\max}; y) - l(b; y)$$

- $\log \lambda$ が大きいとモデルの適合が悪い
 - 標本分布を基に棄却域を決定
 - $2\log \lambda$:逸脱度
 - カイニ乗分布

逸脱度の標本分布

- 逸脱度→対数尤度比統計量:D

$$D = 2[l(b_{\max}; y) - l(b; y)]$$

- パラメータ β の最尤推定量 b $U(b) = 0$

– パラメータベクトル β の対数尤度関数の近似

$$l(\beta) \approx l(b) + (\beta - b)U(b) - \frac{1}{2}(\beta - b)^T \mathcal{J}(b)(\beta - b)$$

$$l(\beta) - l(b) = -\frac{1}{2}(\beta - b)^T \mathcal{J}(b)(\beta - b)$$

$$2[l(\beta) - l(b)] = -(\beta - b)^T \mathcal{J}(b)(\beta - b) \sim \chi^2(p)$$

逸脱度の標本分布

- 逸脱度D

$$D = 2[l(b_{\max}; y) - l(b; y)]$$

$$\begin{aligned} &= 2[l(b_{\max}; y) - l(\beta_{\max}; y)] \\ &\quad - 2[l(b; y) - l(\beta; y)] + 2[l(\beta_{\max}; y) - l(\beta; y)] \end{aligned}$$

飽和モデル: パラメータ数m: 自由度mのカイ二乗分布

対象モデル: パラメータ数p: 自由度pのカイ二乗分布

対象モデルが飽和モデルに適合すると零に近い正の数

逸脱度の標本分布の近似 $D \sim \chi^2(m - p, v)$ 非心パラメータv

逸脱度の標本分布

- 確率変数 Y_i が正規分布
 - 逸脱度はカイ二乗分布
 - ただし分散に依存
- 確率変数 Y_i が他の分布
 - 逸脱度は近似的にカイ二乗分布
 - ちゃんと計算できるものも或る

仮説検定

- ワルド統計量による検定
- スコア統計量による検定
- 逸脱度統計量の差を基にした検定
 - 単純化したモデルM0
 - 一般的(複雑な)モデルM1
 - M0の線形成分がM1の線形成分の特別な場合

仮説検定

- モデルM0の帰無仮説H0

$$H_0: \beta = \beta_0 = [\beta_1, \dots, \beta_q]^t$$

- モデルM1の対立仮説H1

$$H_1: \beta = \beta_1 = [\beta_1, \dots, \beta_p]^t$$

– ただし $q < p < N$

- 対立仮説H1に対する帰無仮説H0の検定

仮説検定

- 対立仮説H1に対する帰無仮説H0の検定

- 逸脱度統計量の差

$$\begin{aligned}\Delta D = D_0 - D_1 &= 2[l(b_{\max}; y) - l(b_0; y)] - 2[l(b_{\max}; y) - l(b_1; y)] \\ &= 2[l(b_1; y) - l(b_0; y)]\end{aligned}$$

- 帰無仮説H0の支持

- どちらのモデルもよく一致する→より簡単なM0

$$D_0 \sim \chi^2(N - q), D_1 \sim \chi^2(N - p) \Rightarrow \Delta D \sim \chi^2(p - q)$$

- 帰無仮説H0の棄却, 対立仮説H1支持

- △Dが棄却域。カイニ乗分布上側 $100 \times \alpha\%$ より大

- M1の方がM0より有意によく記述している

- » M1がよくあてはまるとは限らない