

ベイズ統計

古谷知之

講義概要

- 線形回帰モデルのベイズ推定
 - 通常最小二乗法(OLS)との比較
 - 尤度関数と自然共役事前分布
 - 平均・分散未知の場合の階層ベイズ推定
- 無情報事前分布と非正則事前分布
- 偏差情報量基準
- R演習

線形回帰モデル

- ・サンプル数 n ($i=1, \dots, n$)、説明変数の数 k
- ・被説明変数 y_i 、説明変数 x_{ik} 、未知パラメータ β_k 、誤差項 ε_i
- ・誤差項 ε_i は平均0、分散 σ^2 の正規分布に従う \Rightarrow 分散は未知

$$y_i = \beta_0 + x_{i1}\beta_1 + x_{i2}\beta_2 + \dots + x_{ik}\beta_k + \varepsilon_i,$$

$$\varepsilon_i \sim N(0, \sigma^2)$$

線形回帰モデル

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \cdots & x_{1k} \\ 1 & x_{21} & \cdots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \cdots & x_{nk} \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

$\downarrow \quad \quad \quad \downarrow \quad \quad \quad \downarrow \quad \quad \quad \downarrow$

$y \quad \quad \quad X \quad \quad \quad \beta \quad \quad \quad \varepsilon$

$$\Rightarrow y = X\beta + \varepsilon$$

尤度関数

- データ X 、未知パラメータ β 、分散 σ^2 が与えられた条件下で、被説明変数 y が得られる条件付き確率は
- $x_i = (1, x_{i1}, \dots, x_{ik})$ とするとき
- 尤度関数は正規分布となる

$$p(y_i | x_i; \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(y_i - x_i\beta)^2}{2\sigma^2}\right]$$

尤度関数

- 尤度関数の平均と分散はそれぞれ以下のとおりとなる
- 平均

$$E(y_i | x_i; \beta, \sigma^2) = x_i \beta$$

- 分散

$$V(y_i | x_i; \beta, \sigma^2) = \sigma^2$$

尤度関数

- 全てのiについての尤度関数は

$$p(y | x; \beta, \sigma^2)$$

$$= \prod_{i=1}^n p(y_i | x_i; \beta, \sigma^2)$$

$$= \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \exp \left[-\frac{\sum_{i=1}^n (y_i - x_i \beta)^2}{2\sigma^2} \right]$$

対数尤度関数

- 尤度関数の自然対数をとると

$$\ln[p(y|x; \beta, \sigma^2)]$$

$$= \prod_{i=1}^n \ln[p(y_i|x_i; \beta, \sigma^2)]$$

$$= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - x_i \beta)^2$$

最尤法と最小二乗法

- 最尤法では(対数)尤度関数を最大化することで未知パラメータを得る⇒対数尤度関数は上に凸となる関数
- 対数尤度関数を最大化することは、次式を最小化することと同じ

$$\sum_{i=1}^n (y_i - x_i \beta)^2$$

最小二乗法による解

- 次式を最小化することにより得られる未知パラメータはそれぞれ以下のようになる

$$\sum_{i=1}^n (y_i - x_i \beta)^2$$

- 最小二乗解 $\hat{\beta} = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2}$

$$\hat{\sigma}^2 = \frac{1}{n - (k + 1)} \sum_{i=1}^n (y_i - x_i \hat{\beta})^2$$

自由度: $n - (k + 1)$

尤度関数(全データ)

- データ X 、未知パラメータ β 、分散 σ^2 が与えられた条件下で、被説明変数 y が得られる条件付き確率は
- 尤度関数は正規分布となる

$$p(y | X; \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(y - X\beta)^2}{2\sigma^2}\right]$$

尤度関数(全データ)

- 尤度関数の平均と分散はそれぞれ以下のとおりとなる
- 平均

$$E(y | X; \beta, \sigma^2) = X\beta$$

- 分散

$$V(y | X; \beta, \sigma^2) = \sigma^2$$

尤度関数(全データ)

- 全てのデータについての尤度関数は

$$p(y | X; \beta, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(y - X\beta)^T (y - X\beta)}{2\sigma^2}\right]$$

対数尤度関数(全データ)

- 全てのデータについての尤度関数は

$$\ln p(y | X; \beta, \sigma^2)$$

$$= -\frac{n}{2} \ln 2\pi - \frac{n}{2} \ln \sigma^2 - \frac{(y - X\beta)^T (y - X\beta)}{2\sigma^2}$$

最小二乗法による解(全データ)

- 対数尤度関数を最大化 \Leftrightarrow 最小二乗法による不偏推定量が得られる

$$\hat{\beta} = (X^T X)^{-1} X^T y$$

$$\hat{\sigma}^2 = \frac{1}{n} (y - X\hat{\beta})^T (y - X\hat{\beta})$$

$$v = n - (k + 1) \quad \cdots \text{自由度}$$

↑定数項を加えた変数の数

尤度関数

- 精度 $\tau = 1/\sigma^2$ とすると尤度関数は以下の
ように式変形できる

$$p(y | X; \beta, \tau)$$

$$= \frac{\tau^{1/2}}{(2\pi)^{n/2}} \cdot \left\{ \exp \left[-\frac{\tau}{2} (y - X\beta)^T (y - X\beta) \right] \right\}$$

$$\propto \tau^{1/2} \cdot \left\{ \exp \left[-\frac{\nu \hat{\sigma}^2}{2} \tau \right] \right\}$$

自然共役事前分布と事後分布

- 正規分布の自然共役事前分布にガンマ分布があった
- 精度 $\tau = 1/\sigma^2$ が未知のとき、その事前分布にガンマ分布 $\Gamma(\tau | a, b)$ を乗じると事後分布(ガウス-ガンマ分布)が得られる

$$p(y | X; \beta, \tau) \cdot p(\tau | a, b)$$

$$\propto \tau^{\nu/2} \cdot \exp\left[-\frac{\nu \hat{\sigma}^2}{2} \tau\right] \quad \cdots \text{ガウス分布}$$

$$\cdot \tau^{a-1} \exp(-b\tau) \quad \cdots \text{ガンマ分布}$$

自然共役事前分布と事後分布

- 尤度関数(正規分布)に自然共役事前分布(ガンマ分布)を乗じて得られる事後分布(ガンマ分布)は以下のようになる(正規化係数のガンマ分布はキャンセル)

$$p(y | X; \beta, \tau) \cdot p(\tau | a, b)$$

$$\propto \tau^{\nu/2} \cdot \tau^{a-1} \cdot \exp\left[-b\tau - \frac{\nu\hat{\sigma}^2}{2}\tau\right]$$

$$\propto \tau^{(a+\nu/2)-1} \cdot \exp\left[-\left\{b + \frac{\nu\hat{\sigma}^2}{2}\right\}\tau\right]$$

自然共役事前分布と事後分布

- 事後分布

$$p(y|X;\beta, \tau) \cdot p(\tau|a, b)$$


$$\propto \tau^{(a+\nu/2)-1} \cdot \exp \left[- \left\{ b + \frac{1}{2} (y - X\beta)^T (y - X\beta) \right\} \tau \right]$$

$$\propto \tau^{(a+\nu/2)-1} \cdot \exp \left[- \left\{ b + \frac{\nu}{2} \hat{\sigma}^2 \right\} \tau \right]$$

$$\propto \Gamma \left(a + \frac{\nu}{2}, b + \frac{\nu}{2} \hat{\sigma}^2 \right)$$

階層ベイズ

- 平均と分散(精度)が未知のとき、精度のガンマ分布と尤度関数の正規分布を乗じることで事後分布が得られる



線形回帰モデルのベイズ推定

- ・ 線形回帰モデルは、未知パラメータ β と精度 τ について共役事前分布を与えることによりベイズ推定できる
- ・ 自然共役事前分布

$$p(\beta | \tau, y) = N\left(\left(X^T X\right)^{-1} X^T y, \left(1/\tau\right) \left(X^T X\right)^{-1}\right)$$

$$p(\tau | y) \propto \Gamma\left(a + \frac{\nu}{2}, b + \frac{\nu}{2} \hat{\sigma}^2\right) \propto \Gamma\left(\frac{\nu}{2}, \frac{\nu}{2} \hat{\sigma}^2\right)$$

線形回帰モデルのベイズ推定

- 共役事前分布の超パラメータを導入することによりを次式のように簡略化する

$$p(\beta | \tau, y) \sim N(b_0, (1/\tau)B_0)$$

$$p(\tau | y) \sim \Gamma\left(\frac{\nu_0}{2}, \frac{\nu_0 S_0}{2}\right)$$

- 超パラメータ b_0, B_0, ν_0, S_0 は適当に設定しても問題ない

線形回帰モデルのベイズ推定

- 超パラメータを以下のように置き換える

$$b_0 = (X^T X)^{-1} X^T y$$

$$B_0 = (X^T X)^{-1}$$

$$\nu_0 = \nu$$

$$S_0 = \hat{\sigma}^2 = \frac{1}{\nu} (y - X \hat{\beta})^T (y - X \hat{\beta})$$

線形回帰モデルのベイズ推定

- 以下のような事後分布が得られる

$$p(\beta | \tau, y) \sim N(b_1, B_1)$$

$$p(\tau | y) \sim \Gamma\left(\frac{\nu_1}{2}, \frac{\nu_1 S_1}{2}\right)$$

$$b_1 = B_1 (B_0^{-1} b_0 + \tau X^T y), \quad B_1^{-1} = B_0^{-1} + \tau X^T X,$$

$$\nu_1 = \nu_0 + n, \quad \nu_1 S_1 = \nu_0 S_0 + (y - X b_1)^T (y - X b_1)$$

線形回帰モデルのベイズ推定

- β の周辺事後分布は以下のt分布に従う

$$p(\beta | \tau, y) \sim t(b_1, \hat{\sigma}^2 S_1, \nu_1)$$

$$E(\beta | \tau, y) = b_1$$

$$V(\beta | \tau, y) = \frac{\nu_1 \hat{\sigma}^2}{\nu_1 - 2} S_1$$

線形回帰モデルのギブスサンプリング

- 繰り返し回数 $s=0, \dots, N$ とし、初期値 b_0, B_0, ν_0, S_0 を設定する
 - $p(\beta^{s+1} | \tau^s, y) \sim N(b_1^s, (1/\tau) B_1^s)$ から β^{s+1} を生成する
 - $p(\tau^{s+1} | \beta^{s+1}, y) \sim N(b_1^s, (1/\tau) B_1^s)$ から τ^{s+1} を生成する
 - $s < N$ のとき 1 に戻る。 $s = N$ のとき 計算終了

線形回帰モデルのベイズ推定

- パラメータの事後平均の点推定値は、ベイズ推定の事前情報とOLSの点推定値との重み付け平均

$$E(\beta | X, \tau, y) = b_1 = B_1 \left(B_0^{-1} b_0 + \tau X^T y \right)$$

- 事前情報 B_0^{-1} と τ が非常に小さいときには、事後情報はどうなるだろうか？

線形回帰モデルのベイズ推定

- 事前情報 $B_0^{-1} = 0$ 及び $\nu_0 = 0$ のとき、事後情報はそれぞれ以下のようになる

$$b_1 = (X^T X)^{-1} X^T y = \hat{\beta}$$

$$\nu_1 = n$$

$$S_1 = \frac{1}{\nu_1} (y - Xb_1)^T (y - Xb_1) = \hat{\sigma}^2$$

- すなわち、最小二乗解と同じ結果!!

線形回帰モデルのベイズ推定

- ・推測統計学による線形回帰モデルの推定は、ベイズ推定において事前情報を与えない場合と同じ結果である
- ・事前情報なしでベイズ推定する場合の事前分布を**無情報事前分布**(non-informative prior)という
- ・ベイズ統計では未知パラメータ β がランダム変数であると考えるが、推測統計学では $\hat{\beta}$ をランダム変数と考えているにほかない

線形回帰モデルのベイズ推定

- 無情報事前分布は、積分しても1とならない(定数に収束しない)
- このような事前分布を**非正則事前分布**(improper prior)という
- 非正則事前分布の例として、一様分布が挙げられる
- 推測統計学による線形回帰モデルの不偏推定量は、事前情報に一様分布を与えた場合のベイズ推定とみなすこともできる

偏差情報量基準 (Deviance Information Criterion: DIC)

- ・モデルの当てはまりの良さを示す指標
- ・未知パラメータ θ が得られた条件下でデータ y が求められる確率 $p(y | \theta) \Rightarrow$ つまり尤度関数
- ・対数尤度を用いて得られる次式をデヴィアンスとよぶ

$$D(\theta) = -2 \log p(y | \theta)$$

偏差情報量基準

- ・パラメータ点推定値に対するデヴィアンス

$$D(\bar{\theta}) = -2 \log p(y | \bar{\theta})$$

- ・デヴィアンスの平均値

$$\bar{D}(\theta) = E_{\theta|y} [-2 \log p(y | \theta)]$$

偏差情報量基準

- 有効なパラメータ数

$$pD = \bar{D}(\theta) - D(\bar{\theta})$$

- 偏差情報量基準(DIC)

$$\begin{aligned} DIC &= \bar{D}(\theta) + pD \\ &= D(\bar{\theta}) + 2pD \end{aligned}$$

線形回帰モデルのベイズ推定例

```
> swiss.post <- MCMCregress(Fertility~Agriculture+Education+Catholic  
+Infant.Mortality, data=swiss, burnin = 1000, mcmc = 10000, thin = 1)  
> summary(swiss.post)
```

Iterations = 1001:11000

Thinning interval = 1

Number of chains = 1

Sample size per chain = 10000


1. Empirical mean and standard deviation for each variable,
plus standard error of the mean:

	Mean	SD	Naive SE	Time-series SE
(Intercept)	62.0820	9.75835	0.0975835	0.0975835
Agriculture	-0.1538	0.06894	0.0006894	0.0006723
Education	-0.9782	0.15212	0.0015212	0.0015212
Catholic	0.1246	0.02945	0.0002945	0.0002945
Infant.Mortality	1.0753	0.38785	0.0038785	0.0038785
sigma2	53.9003	12.37564	0.1237564	0.1399208


2. Quantiles for each variable:

	2.5%	25%	50%	75%	97.5%
(Intercept)	42.96315	55.5923	62.0890	68.4122	81.46942
Agriculture	-0.29126	-0.1995	-0.1535	-0.1074	-0.02082
Education	-1.27996	-1.0778	-0.9786	-0.8768	-0.68357
Catholic	0.06697	0.1049	0.1243	0.1444	0.18293
Infant.Mortality	0.30498	0.8190	1.0739	1.3307	1.83538
sigma2	34.79708	45.0713	52.1649	60.6398	83.16363


Trace of (Intercept)




Density of (Intercept)




Trace of Agriculture




Density of Agriculture




Trace of Education




Density of Education




Trace of Catholic




Density of Catholic




Trace of Infant.Mortality




Density of Infant.Mortality



Trace of sigma2



Density of sigma2



```
> geweke.diag(swiss.post2)
```

Fraction in 1st window = 0.1

Fraction in 2nd window = 0.5

	(Intercept)	Agriculture	Education	Catholic
	0.5021	-0.2424	1.0638	0.9029
Infant.Mortality		sigma2		
	-0.8999	1.1620		

```
>
```

```
> raftery.diag(swiss.post2)
```

Quantile (q) = 0.025

Accuracy (r) = +/- 0.005

Probability (s) = 0.95

	Burn-in (M)	Total (N)	Lower bound (Nmin)	Dependence factor (I)
(Intercept)	4	7482	3746	2.00
Agriculture	4	7420	3746	1.98
Education	4	7482	3746	2.00
Catholic	4	7542	3746	2.01
Infant.Mortality	4	7420	3746	1.98
sigma2	4	7482	3746	2.00