

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(復習)
- モデル選択
 - ベイズファクター(BF)
- BFとp値を巡る議論
- マルチレベル・モデルのベイズ推定
- R演習
 - R2jags

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

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

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

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

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

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

$$v_0 = v$$

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

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

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

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

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

$$\nu_1 = \nu_0 + n, \quad \nu_1 S_1 = \nu_0 S_0 + (y - Xb_1)^T (y - Xb_1)$$

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

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

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

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

```
> print(swiss.jags, digits=3)
```

```
Inference for Bugs model at "/Library/Frameworks/R.framework/Versions/3.0/  
Resources/library/R2jags/model/model1.txt", fit using jags,
```

```
3 chains, each with 10000 iterations (first 1000 discarded), n.thin = 9
```

```
n.sims = 3000 iterations saved
```

	mu.vect	sd.vect	2.5%	25%	50%	75%	97.5%	Rhat	n.eff
beta0	67.105	13.990	45.178	59.293	67.151	74.183	89.391	1.003	1400
beta1	-0.172	0.111	-0.312	-0.220	-0.171	-0.122	-0.026	1.129	1900
beta2	-0.264	0.354	-0.766	-0.434	-0.258	-0.090	0.257	1.094	3000
beta3	-0.870	0.190	-1.227	-0.992	-0.873	-0.747	-0.505	1.001	3000
beta4	0.104	0.039	0.035	0.080	0.104	0.128	0.176	1.009	3000
beta5	1.071	0.402	0.298	0.812	1.068	1.339	1.858	1.001	2100
tau	0.020	0.004	0.012	0.016	0.019	0.022	0.029	1.009	1200
deviance	319.807	7.890	313.920	316.642	318.926	321.825	329.118	1.023	1400

For each parameter, n.eff is a crude measure of effective sample size,
and Rhat is the potential scale reduction factor (at convergence, Rhat=1).

DIC info (using the rule, $pD = \text{var}(\text{deviance})/2$)

$pD = 31.1$ and $DIC = 350.9$

DIC is an estimate of expected predictive error (lower deviance is better).

```
> gelman.diag(as.mcmc(swiss.jags))
```

Potential scale reduction factors:

	Point est.	Upper C.I.
beta0	1.003	1.01
beta1	1.004	1.02
beta2	1.000	1.00
beta3	1.002	1.01
beta4	0.999	1.00
beta5	1.002	1.01
deviance	1.004	1.01
tau	1.000	1.00

Multivariate psrf

1.01

```
> geweke.diag(as.mcmc(swiss.jags))
```

```
[[1]]
```

```
Fraction in 1st window = 0.1
```

```
Fraction in 2nd window = 0.5
```

beta0	beta1	beta2	beta3	beta4	beta5	deviance	tau
1.0412	-0.6132	-0.2245	-1.2326	-1.7890	-0.7599	1.1214	-1.2407

```
[[2]]
```

```
Fraction in 1st window = 0.1
```

```
Fraction in 2nd window = 0.5
```

beta0	beta1	beta2	beta3	beta4	beta5	deviance	tau
-0.59821	1.39684	-1.31319	1.67479	-1.04701	0.74338	1.25556	-0.07713

```
[[3]]
```

```
Fraction in 1st window = 0.1
```

```
Fraction in 2nd window = 0.5
```

beta0	beta1	beta2	beta3	beta4	beta5	deviance	tau
0.4123	-0.7620	-0.6936	0.7896	1.1846	0.9047	1.3075	-1.9717

```
> raftery.diag(as.mcmc(swiss.jags))
```

```
[[1]]
```

Quantile (q) = 0.025

Accuracy (r) = +/- 0.005

Probability (s) = 0.95

You need a sample size of at least 3746 with these values of q, r and s

```
[[2]]
```

Quantile (q) = 0.025

Accuracy (r) = +/- 0.005

Probability (s) = 0.95

You need a sample size of at least 3746 with these values of q, r and s

```
[[3]]
```

Quantile (q) = 0.025

Accuracy (r) = +/- 0.005

Probability (s) = 0.95

You need a sample size of at least 3746 with these values of q, r and s

モデル間の比較

- いま、2つのモデル M_0 と M_1 を推定しどちらがよいか比較したい
- 2つのモデルの事後分布を簡略化してそれぞれ以下のように表す

– モデル M_0 : $p(\beta^{M_0}, \tau^{M_0} | y) = p(M_0 | y)$

– モデル M_1 : $p(\beta^{M_1}, \tau^{M_1} | y) = p(M_1 | y)$

モデル間の比較

- ベイズの定理から、事後分布を尤度と事前分布を用いて書き換えると、

$$p(M_0 | y) = p(y | M_0) p(M_0) / p(y)$$

$$p(M_1 | y) = p(y | M_1) p(M_1) / p(y)$$

- 2つのモデルの比を取ると

$$\frac{p(M_0 | y)}{p(M_1 | y)} = \frac{p(y | M_0)}{p(y | M_1)} \cdot \frac{p(M_0)}{p(M_1)}$$

ベイズ・ファクター

- 事後分布の比 = 尤度比 × 事前分布の比

$$\underbrace{\frac{p(M_0 | y)}{p(M_1 | y)}}_{\text{Posterior odds}} = \underbrace{\frac{p(y | M_0)}{p(y | M_1)}}_{\text{Bayes factor}} \cdot \underbrace{\frac{p(M_0)}{p(M_1)}}_{\text{Prior odds}}$$

(B₀₁)

- 2つのモデルを比較して、モデルM₀とM₁のどちらが優勢かは事前にわからない
p(M₀) = p(M₁) = 1/2なので、ベイズ・ファクターB₀₁の値がモデルの優劣を決める

ベイズ・ファクター

- ベイズ・ファクター B_{01} の値により、帰無仮説モデル M_0 と提案モデル M_1 の指示度が変わる

Jeffreys (1961)

ベイズ・ファクター	解釈
$\log B_{01} < 0$	帰無仮説モデル M_0 を支持
$0 < \log B_{01} < 0.5$	M_1 はよくも悪くもない
$0.5 < \log B_{01} < 1$	M_1 は十分である
$1 < \log B_{01} < 2$	M_1 を強く支持できる
$2 < \log B_{01}$	M_1 は決定的に支持できる

BFとp値

- p値はしばしば帰無仮説の事後確率と誤解されているのではないか
- 単純な帰無仮説に対して、p値は帰無仮説のエビデンスをかなり水増ししているのではないか
- 対立仮説は帰無仮説の片側分布に対応しているので、p値を用いるなら両側検定より片側検定が適しているのではないか

BFとp値

- H_0 と H_1 に等しい事前確率を与えた場合、

両側検定	p値		
	0.05	0.01	0.001
t値	1.96	2.58	3.29
BF	0.15	0.04	0.004
$\min(H_0 x)$	12.8%	3.5%	0.4%

片側検定	p値		
	0.05	0.01	0.001
t値	1.64	2.33	3.09
BF	0.26	0.07	0.008
$\min(H_0 x)$	20.5%	6.3%	0.8%

Edwards et al. (1963)

p値にまつわる12の誤解

S. Goodman (2008)



Seminars in
HEMATOLOGY

A Dirty Dozen: Twelve *P*-Value Misconceptions

Steven Goodman

Table 1 Twelve *P*-Value Misconceptions

1	<i>If $P = .05$, the null hypothesis has only a 5% chance of being true.</i>
2	<i>A nonsignificant difference (eg, $P \geq .05$) means there is no difference between groups.</i>
3	<i>A statistically significant finding is clinically important.</i>
4	<i>Studies with <i>P</i> values on opposite sides of .05 are conflicting.</i>
5	<i>Studies with the same <i>P</i> value provide the same evidence against the null hypothesis.</i>
6	<i>$P = .05$ means that we have observed data that would occur only 5% of the time under the null hypothesis.</i>
7	<i>$P = .05$ and $P \leq .05$ mean the same thing.</i>
8	<i><i>P</i> values are properly written as inequalities (eg, "$P \leq .02$" when $P = .015$)</i>
9	<i>$P = .05$ means that if you reject the null hypothesis, the probability of a type I error is only 5%.</i>
10	<i>With a $P = .05$ threshold for significance, the chance of a type I error will be 5%.</i>
11	<i>You should use a one-sided <i>P</i> value when you don't care about a result in one direction, or a difference in that direction is impossible.</i>
12	<i>A scientific conclusion or treatment policy should be based on whether or not the <i>P</i> value is significant.</i>

マルチレベル・モデル

- グループ $j(=1, \dots, m)$ に属する個人 $i(=1, \dots, n)$ を考える
- 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
- このとき、

$$y_{ij} = \beta_0 + x_{ij1}\beta_1 + x_{ij2}\beta_2 + \dots + x_{ijk}\beta_k + \varepsilon_i,$$

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

マルチレベル・モデル

- ① 定数項と回帰係数が変動しないモデル

$$y_{ij} = \beta_0 + x_{ij1}\beta_1 + x_{ij2}\beta_2 + \cdots + x_{ijk}\beta_k + \varepsilon_i$$

- ② 定数項のみ変動するモデル

$$y_{ij} = \beta_{j0} + x_{ij1}\beta_1 + x_{ij2}\beta_2 + \cdots + x_{ijk}\beta_k + \varepsilon_i$$

- ③ 回帰係数のみ変動するモデル

$$y_{ij} = \beta_0 + x_{ij1}\beta_{j1} + x_{ij2}\beta_{j2} + \cdots + x_{ijk}\beta_{jk} + \varepsilon_i$$

- ④ 定数項と回帰係数が変動するモデル

$$y_{ij} = \beta_{j0} + x_{ij1}\beta_{j1} + x_{ij2}\beta_{j2} + \cdots + x_{ijk}\beta_{jk} + \varepsilon_i$$

ランダム効果と固定効果

- ランダム効果
 - 回帰係数や定数項について、個人や地域・グループでの変動を認めるモデル
- 固定効果
 - 上記のような変動を認めないモデル
- 混合効果
 - ランダム効果と固定効果が混在したモデル

マルチレベル・モデル

- レベル 1 = lower level

$$y_{ij} = \beta_0 + x_{ij1}\beta_1 + \varepsilon_{ij}, \quad \varepsilon_{ij} \sim N(0, \sigma_y^2)$$

$$y_{ij} \sim N(\beta_0 + x_{ij1}\beta_1, \sigma_y^2)$$

- レベル 2 = upper level

グループによる変動を受けない (固定効果)

↓
グループによる変動を受ける (ランダム効果)

$$\beta_{j0} = \gamma_{00} + \gamma_{10}u_{j0} + \eta_{j0},$$

$$\beta_{j1} = \gamma_{01} + \gamma_{11}u_{j0} + \eta_{j1}$$

$$\eta_{jk} \sim N(0, \sigma_\eta^2), \quad \beta_{jk} \sim N(\mu_k, \sigma_{\beta_k}^2), \quad k = \{0, 1\}$$

マルチレベル・モデル

- レベル1とレベル2をあわせると

$$\begin{aligned} y_{ij} &= \beta_0 + x_{ij1}\beta_1 + \varepsilon_{ij} \\ &= (\gamma_{00} + \gamma_{10}u_{j0}) + (\gamma_{01} + \gamma_{11}u_{j0})x_{ij1} + \eta_j + \varepsilon_{ij} \\ &= \underbrace{(\gamma_{00} + \gamma_{01}x_{ij1})}_{\Leftrightarrow \text{固定効果}} + \underbrace{(\gamma_{10}u_{j0} + \gamma_{11}u_{j0}x_{ij1})}_{\text{ランダム効果}} + \eta_j + \varepsilon_{ij} \end{aligned}$$

$$y_i = X_i B + Z_i b_i$$

$$b_i \sim N(0, \sigma_{b_i}^2)$$

マルチレベル・モデルのベイズ推定

$$y_i \sim N(X_i B, \sigma_y^2)$$

$$\begin{pmatrix} \beta_{j0} \\ \beta_{j1} \end{pmatrix} \sim N \left(\begin{pmatrix} \gamma_{00} + \gamma_{10} u_{j0} \\ \gamma_{01} + \gamma_{11} u_{j1} \end{pmatrix}, \begin{pmatrix} \sigma_{\beta_0}^2 & \rho \sigma_{\beta_0} \sigma_{\beta_1} \\ \rho \sigma_{\beta_0} \sigma_{\beta_1} & \sigma_{\beta_1}^2 \end{pmatrix} \right)$$

$$B \sim N(0, V_B)$$

$$\varepsilon_{ij} \sim N(0, \sigma_y^2), \eta_{jk} \sim N(0, \sigma_\eta^2)$$

マルチレベル・モデルのベイズ推定

- 未知パラメータ

$$y_i | X_i, B, \sigma_y^2 \sim N(X_i B, \sigma_y^2)$$

$$B | Z_i, \sigma_{b_i}^2, V_B \sim N(0, V_B)$$

$$V_B | \nu, V \sim IW(\nu, V)$$

$$\sigma_y^2 | s_{y_i}^2, \nu \sim \eta_j s_{y_i}^2 / \chi_{\eta_j}^2$$

$$b_i | \sigma_{b_i}^2 \sim N(0, \sigma_{b_i}^2)$$

$$\sigma_{b_i}^2 | \eta_i \sim N(0, \sigma_{b_i}^2)$$

ウィシャート分布

- x_i が n 個の p 次元多変量正規分布に従うとき

$$x_i \sim N(0, \Sigma)$$

- 標本分散共分散行列 X は逆ウィシャート分布に従う

$$X = \sum_{i=1}^n x_i \cdot x_i^T$$

$$X \sim W(X; \Sigma, n, p)$$

- ベイズ統計では多変量正規分布の共分散行列の自然共役事前分布として用いられる

ウィシャート分布

- ウィシャート行列はカイ二乗分布を多次元化したものである

$$W(X; \Sigma, n, p) = \frac{|\Sigma|^{-\frac{n}{2}} |X|^{\frac{n-p-1}{2}}}{2^{\frac{np}{2}} \cdot \Gamma_p\left(\frac{n}{2}\right)} \cdot \exp\left(-\frac{1}{2} \text{tr} \Sigma^{-1} X\right)$$

- $\Gamma_p(a)$ は p 次元多変量 Γ 関数

$$\Gamma_p(p) = \pi^{\frac{p(p-1)}{4}} \prod_{j=1}^p \left[a - \frac{1}{2}(j-1) \right]$$

逆ウィシャート分布

- $W(\Sigma, n, p)$ に従う X を $V=X^{-1}$ とすると、 V の分布を逆ウィシャート分布という

$$IW(X; \Sigma, n, p) = \frac{|\Sigma|^{-\frac{n}{2}} |V|^{-\frac{n+p+1}{2}}}{2^{\frac{np}{2}} \cdot \Gamma_p\left(\frac{n}{2}\right)} \cdot \exp\left(-\frac{1}{2} \text{tr} \Sigma^{-1} V^{-1}\right)$$