

第10章 ギブスサンプリング

10.3 プロビットリンクによる2値反応

10.4 平均分割表の推定

茨城大学工学部情報工学科
國井慎也

プロビットリンクによる2値反応の回帰

- 4.4節では、投薬量レベルを関数として、動物の死亡確率の回帰問題を扱った。
 - 投薬量レベルの1変数のみ

- これを一般化して、複数の共変量の関数として表すことを考える。
 - プロビット回帰モデル

プロビット回帰のモデル

- 2値の反応: y_1, \dots, y_n 例 ($y_i=1$ なら生存, $y_i=0$ なら死亡)
- 共変量: x_{i1}, \dots, x_{ik} 例 (年齢、性別)
- パラメータ: β_1, \dots, β_k
- プロビット回帰モデルでの $y_i=1$ となる確率 p_i は以下で表すことができる

$$p_i = P(y_i = 1) = \Phi(x_{i1}\beta_1 + \dots + x_{ik}\beta_k)$$

- $\Phi()$ は標準正規分布のcdf(累積分布関数)である

プロビット回帰のモデル(2)

- β の事後分布

-事前分布に一様事前分布を仮定

$$g(\beta|y) \propto \prod_{i=1}^n p_i^{y_i} (1-p_i)^{1-y_i}$$

- 潜在データ

$$Z_i = x_{i1} \beta_1 + \dots + x_{ik} \beta_k + \varepsilon_i$$

ε_i は、標準正規分布からのランダム標本

- 最終的に、モデルは以下のようなになる

$$P(y_i=1) = P(Z_i > 0) = \Phi(x_{i1} \beta_1 + \dots + x_{ik} \beta_k)$$

ギブスサンプリングの構成

- ギブスサンプリングアルゴリズムは、潜在データ Z_i とパラメータベクトル β の結合事後分布から構成される。

- β の条件付事後分布

$$[\beta | Z, data] \approx N_k \left((X' X)^{-1} X' Z, (X' X)^{-1} \right)$$

- Z_i の条件付確率 (Z_1, \dots, Z_n は独立と仮定)

$$[Z_i | \beta, data] \approx N(x_i \beta, 1) I(Z_i > 0) \quad (y_i = 1 \text{ のとき})$$

$$[Z_i | \beta, data] \approx N(x_i \beta, 1) I(Z_i < 0) \quad (y_i = 0 \text{ のとき})$$

Rでの実行(1)

- 使用するデータ

LearnBayesのdonnerのデータセット

シエラネバダ山脈を越えようとした移民データ

大量の餓死者が出た

→生存確率を求める

- データの内容

y_i : i 番目の生存ステータス(1なら生存,0なら非生存)

$MALE_i$: 性別(1なら男性,0なら女性)

AGE_i : 年齢 (15歳以上)

Rでの実行(2)

- プロビットリンクのモデルは以下のようなになる

$$P(y_i=1) = \Phi(\beta_0 + \beta_1 MALE_i + \beta_2 AGE_i)$$

これに合うような β を求める

- まずは最尤推定法で求める

- `data(donner)` #データ読み込み
- `> attach(donner)`
- `> X<-cbind(1,age,male)` #デザイン行列Xを作成
- `> fit <- glm(survival ~ X - 1, family = binomial(link = probit))`
#最尤推定にはglm関数, β が二項分布に従うのでbinomial,プロビットリンクを指定
- `> summary(fit)`

Rでの実行(3)

• 最尤推定法出力結果

- Call:
- `glm(formula = survival ~ X - 1, family = binomial(link = probit))`
- Deviance Residuals:
 - Min 1Q Median 3Q Max
 - -1.7420 -1.0555 -0.2756 0.8861 2.0339
- Coefficients:
 - Estimate Std. Error z value Pr(>|z|)
 - X 1.91730 0.76438 2.508 0.0121 *
 - Xage -0.04571 0.02076 -2.202 0.0277 *
 - Xmale -0.95828 0.43983 -2.179 0.0293 *
 - ---
- Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
- (Dispersion parameter for binomial family taken to be 1)
- Null deviance: 62.383 on 45 degrees of freedom
- Residual deviance: 51.283 on 42 degrees of freedom
- AIC: 57.283
- Number of Fisher Scoring iterations: 5

Rでの実行(4)

- ギブスサンプリングで β を求める

-bayes.probit関数

引数: 2値反応ベクトル、デザイン行列、サイクル数m



- ```
> m<-1000
```
- 
- ```
> fit <- bayes.probit(survival, X, m) #ギブスサンプリングを行う
```
- ```
> apply(fit$beta ,2,mean) #各 β の平均を求める
```
- ```
[1] 2.07886032 -0.04954357 -1.04367756
```
-
- ```
> apply(fit$beta ,2,sd) # 標準偏差を求める
```
- ```
[1] 0.79242639 0.02078837 0.45506060
```

Rでの実行(5)

- 15歳から65歳までの男性のみの生存率を求める
 - bprobit.probs関数: 共変量の集合に対する確率の事後分布をシミュレーションした標本から計算する

```
a=seq(15,65) #15歳から65歳まで
> X1=cbind(1,a,1)#共変量からなるベクトルを作成
> p.male=bprobit.probs(X1,fit$beta) #男性のみの生存確率を計算する
#以下のコマンドは、グラフを描くため
> plot(a,apply(p.male,2,quantile,.5),type="l",ylim=c(0,1),
+      xlab="age",ylab="Probability of Survival")
> lines(a,apply(p.male,2,quantile,.05),lty=2)
> lines(a,apply(p.male,2,quantile,.95),lty=2)
```

Rでの実行(6)



左図: 男性の生存確率、右図: 女性の生存確率

5%,50%,95%分位点をプロット

有情報事前分布

- 先ほどは β に無情報一様事前分布を仮定
→有情報事前分布を与えることを考える
- 事前分布として、平均ベクトル β_0 、分散共分散行列 V_0 の多変量正規分布を割り当てる。
- この場合のギブスサンプリングも $[\beta|Z]$ と $[Z|\beta]$ からサンプリングされる。 β の事前分布は以下のように修正される。

$$[\beta|Z, data] \approx N_k(\beta^1, V_1)$$

$$\beta^1 = (X'X + V_0^{-1})^{-1} (X'Z + V_0^{-1}\beta_0)$$

$$V_1 = (X'X + V_0^{-1})^{-1}$$

モデル比較

- モデル{性別、年齢}{性別}{年齢}{ゼロモデル}のモデルを比較する。

比較の基準にベイズファクターを用いる

- ベイズファクター

2つのモデルの支持する度合いを計算する

$$BF = \frac{m_1(y)}{m_2(y)} \quad m(y) = \frac{f(y|\beta)g(\beta)}{g(\beta|y)}$$

$f(y|\beta)$: サンプルング密度、 $g(\beta)$: 事前密度、 $f(\beta|y)$ 事後密度

m(y)の計算

- m(y)の対数をとると

$$\log m(y) = \log f(y|\beta) + \log g(\beta) - \log g(\beta|y)$$

右辺第1項と第2項は既知であるが第3項の計算は難しい

- g(β|y)の計算

βの特定の値をβ*としβ=β*とおき、潜在データ変数Zを導入すると

$$g(\beta^*|y) = \int g(\beta^*|Z, y) g(Z|y) dZ$$

$m(y)$ の計算(2)

$[\beta|Z,y]$ は、正規分布 (β^1, V_1) であるので、 Z 周辺事後密度から $g(\beta^*|y)$ をシミュレーションできる

$$g(\beta^*|y) \approx \frac{1}{m} \sum_{j=1}^m g(\beta^*|Z^j, y) = \frac{1}{m} \sum_{j=1}^m \Phi(\beta^*; \beta^1, V_1)$$

$\{Z^j\}$ はシミュレーションによる m 個の潜在データの標本集合

$\Phi(x; \mu, V)$ は x で評価した平均 μ で分散共分散行列 V の多変量正規密度

- 最終的に、周辺密度の対数の推定値は以下のようになる

$$\log m(y) \approx \log f(y|\beta) + \log g(\beta) - \frac{1}{m} \sum_{j=1}^m \Phi(\beta^*; \beta^1, V_1)$$

Rでの実行(7)

- $\log m(y)$ を計算する

`bayes.brobit()`:主観事前分布が使われている場合の事後分布を計算する関数

引数として

- `y`:2値反応ベクトル
- `X`:デザイン行列
- サイクル数
- `list(beta,P)`
- `beta`:事前平均ベクトル
- `P`:事前精度行列

Rでの実行(8)

- `data(donner)` #データ読み込み
- `> y=donner$survival` #2値反応ベクトルをyに代入
- `> X=cbind(1,donner$age,donner$male)` #デザイン行列Xを作成
- `>`
- `> beta0=c(0,0,0); c0=100` #beta0に β の事前平均ベクトルを割り当てる #c0は β の位置についての確信を与える,数値が大きいほど曖昧な事前知識を反映する
- `> P0=t(X)%*%X/c0` #事前精度行列
- `>`
- `> bayes.probit(y,X,1000,list(beta=beta0,P=P0))$log.marg` #フルモデル
- `[1] -31.5153`
- `>`
- `> bayes.probit(y,X[,-2],1000,` #年齢のみのモデル
- `+ list(beta=beta0[-2],P=P0[-2,-2]))$log.marg`
- `[1] -32.78796`
- `>`
- `> bayes.probit(y,X[,-3],1000,` #性別のみのモデル
- `+ list(beta=beta0[-3],P=P0[-3,-3]))$log.marg`
- `[1] -32.01771`

BFの計算

- {年齢、性別}モデルと{年齢}モデルのBFの計算

$$BF = \frac{\exp(-31.5153)}{\exp(-32.78796)} = 3.570337$$

結果的に、{年齢、性別}モデルのほうが支持される

10.4 はじめに

- この節では、高校での成績から大学での成績を推定をすることを説明する

HSR: 高校での成績ランク

ACT: 高校3年生に課せられる標準化テスト

GPA: 大学での成績

- 使用するデータ

LearnBayesのiowagpaというデータファイル

40行からなるファイルで、各行にはGPAの標本平均、標本サイズ、高校での百分率での成績ランク、ACTスコアが記録されている

10.4.1 2元分割表の作成

- まず、2元分割表を作成する

行に、高校での成績ランク(HSR)、列にACTCスコア、表の数値に平均GPAを表している

```
• > library(LearnBayes) #パッケージ読み込み
• > data(iowagpa) #データの読み込み
#以下は、2元表を作成するコマンド
• > rlabels = c("91-99", "81-90", "71-80", "61-70",
"51-60", "41-50",
• + "31-40", "21-30")
• > clabels = c("16-18", "19-21", "22-24", "25-27",
"28-30")
• > gpa = matrix(iowagpa[, 1], nrow = 8, ncol = 5,
byrow = T)
• > dimnames(gpa) = list(HSR = rlabels, ACTC =
clabels)
• > gpa
```

```
• ACTC
• HSR 16-18 19-21 22-24 25-27 28-30
• 91-99 2.64 3.10 3.01 3.07 3.34
• 81-90 2.24 2.63 2.74 2.76 2.91
• 71-80 2.43 2.47 2.64 2.73 2.47
• 61-70 2.31 2.37 2.32 2.24 2.31
• 51-60 2.04 2.20 2.01 2.43 2.38
• 41-50 1.88 1.82 1.84 2.12 2.05
• 31-40 1.86 2.28 1.67 1.89 1.79
• 21-30 1.70 1.65 1.51 1.67 2.33
```

2元分割表の作成(2)

- 次の表では、高校での成績ランクとACTスコアの組み合わせごとに該当する学生数を表している。

```
> samplesizes = matrix(iowagpa[, 2], nrow = 8, ncol = 5, byrow = T)
> dimnames(samplesizes) = list(HSR = rlabels, ACTC = clabels)
> samplesizes
```

• ACTC					
• HSR	16-18	19-21	22-24	25-27	28-30
• 91-99	8	15	78	182	166
• 81-90	20	71	168	178	91
• 71-80	40	116	180	133	46
• 61-70	34	93	124	101	19
• 51-60	41	73	62	58	9
• 41-50	19	25	36	49	16
• 31-40	8	9	15	29	9
• 21-30	4	5	9	11	1

順序制約

- 成績における順序制約

GPAは、次の2つの順序制約を満たすと考えるのが妥当

u_{ij} : HRSのレベルが*i*、ACTスコアのレベルが*j*の学生の母集団のGPAの平均

$$u_{i1} \leq u_{i2} \leq \dots \leq u_{i5}$$


これは、ACTスコアが高くなればなるほどGPAも高くなるという確信を表す

$$u_{1j} \leq u_{2j} \leq \dots \leq u_{9j}$$

これは、HSRスコアが高くなればなるほどGPAも高くなるという確信を表す

- `act = seq(17, 29, by = 3)` #x軸の範囲を指定
- `matplot(act, t(gpa), type = "l", lwd = 3, #以下、グラフを作成するコマンド`
- `xlim = c(17, 34), col=1:8, lty=1:8)`
- `legend(30, 3, lty = 1:8, lwd = 3, legend = c("HSR=9", "HSR=8",`
- `"HSR=7", "HSR=6", "HSR=5", "HSR=4", "HSR=3", "HSR=2"), col=1:8)`

- 高校での成績ランク(HSR)とACTスコアのレベルごとのGPA平均
- 順序制約を完全に満たしていないので、順序制約に適合するよう母集団平均を平滑化した推定値を求めることが望ましい



10.4.2 順序制約に従うモデル

- 母集団平均は、順序制約に従うが、平均の位置については知識がないとすると、

事前分布は、

$$g(\mu) \propto c(\mu \in A)$$

A は、順序制約にしたがう μ の値の空間を意味する

- μ の尤度関数

y_{ij} : GPAの標本平均, n_{ij} : 標本サイズ

観測値 y_{ij} は、それぞれ独立で、平均 μ_{ij} , 分散 σ^2/n_{ij} の正規分布に従うと仮定。 σ は既知とすると

$$L(\mu) = \prod_{i=1}^8 \prod_{j=1}^5 \exp\left\{-\frac{n_{ij}}{2\sigma^2}(y_{ij} - \mu_{ij})^2\right\}$$

順序制約に従うモデル(2)

- 事後密度は以下で与えられる

$$g(\mu|y) \propto L(\mu)$$

- 次に、ギブスサンプリングを行う

ordergibbs関数: 順序制約に従うギブスサンプリングを行う

引数

標本平均と標本サイズを含む行列

サイクル数

GPAの事後平均を求める


- `ordergibbs`関数を使って、サンプリングを行い、GPAの事後平均を求める。サイクル数は5000回。

```
> MU = ordergibbs(iowagpa, 5000) #順序制約に従ったギブスサンプリングを行う
> postmeans = apply(MU, 2, mean) #求めた標本の平均を求める
> postmeans = matrix(postmeans, nrow = 8, ncol = 5) ##以下、表を作成するコマンド
> postmeans=postmeans[seq(8,1,-1),]
> dimnames(postmeans)=list(HSR=rlabels,ACTC=clabels)
> round(postmeans,2)
```

```
• ACTC
• HSR  16-18 19-21 22-24 25-27 28-30
• 91-99 2.65 2.92 3.01 3.09 3.34
• 81-90 2.41 2.62 2.73 2.78 2.92
• 71-80 2.33 2.47 2.62 2.67 2.71
• 61-70 2.20 2.29 2.33 2.37 2.50
• 51-60 2.00 2.11 2.15 2.31 2.40
• 41-50 1.76 1.86 1.94 2.10 2.21
• 31-40 1.59 1.74 1.81 1.91 2.05
• 21-30 1.24 1.43 1.56 1.70 1.88
```

GPAの事後平均を求める(2)

- `matplot(act, t(postmeans), type = "l", lty=1:8, lwd = 3, col = 1, xlim = c(17, 34))`
- `legend(30, 3, lty = 1:8, lwd = 2, legend = c("HSR=9", "HSR=8",`
- `"HSR=7", "HSR=6", "HSR=5", "HSR=4", "HSR=3", "HSR=2"))`



- 順序制約空間に無情報事前分布を使ったGPAの事後平均プロット
順序制約に従っているのがわかる

順序制約が与える影響

- 順序制約という事前の確信が推論に与える影響を調べたい
→セル平均事後標準偏差を計算し、古典的な標準偏差と比べること

- まず、事後標準偏差を求める

- `postsds = apply(MU, 2, sd)` #平均の事後標準偏差を求める
- `> postsds = matrix(postsds, nrow = 8, ncol = 5)` ##以下、表を作成するコマンド
- `> postsds=postsds[seq(8,1,-1),]`
- `> dimnames(postsds)=list(HSR=rlabels,ACTC=clabels)`
- `> round(postsds,3)`

	ACTC				
HSR	16-18	19-21	22-24	25-27	28-30
91-99	0.140	0.085	0.054	0.044	0.051
81-90	0.078	0.059	0.038	0.038	0.063
71-80	0.065	0.052	0.039	0.039	0.046
61-70	0.066	0.040	0.037	0.039	0.081
51-60	0.073	0.053	0.055	0.049	0.073
41-50	0.082	0.067	0.067	0.071	0.086
31-40	0.116	0.079	0.073	0.074	0.096
21-30	0.184	0.139	0.120	0.112	0.131

順序制約が与える影響(2)

- 古典的な観測標本平均 y_{ij} の標準誤差は $SE(y_{ij}) = \sigma / \sqrt{n_{ij}}$ で与えられる。
- 次の表は、すべてのセルについての比 $\{SD(\mu_{ij}|y) / SE(u_{ij})\}$ を計算している。

- `> s=.65 #σ=0.65と仮定`
- `> se=s/sqrt(samplesizes) #SEを計算`
- `> round(poststds/se,2) #SD/SEを計算し、表を作成する`

ACTC					
HSR	16-18	19-21	22-24	25-27	28-30
91-99	0.61	0.51	0.74	0.90	1.00
81-90	0.54	0.76	0.75	0.77	0.92
71-80	0.63	0.86	0.80	0.69	0.48
61-70	0.59	0.59	0.63	0.60	0.54
51-60	0.72	0.69	0.66	0.57	0.34
41-50	0.55	0.52	0.62	0.77	0.53
31-40	0.50	0.36	0.43	0.61	0.44
21-30	0.57	0.48	0.55	0.57	0.20

- ほとんどのセルの比が0.5から0.7にあるので、順序制約のある事前分布を利用したことで、有意な事前情報が加えられたとを示している。

10.4.3 階層的回帰モデル

- GPAと二つの説明変数との関係を反映するために階層的回帰事前分布を構成する

- μ の分布

平均が独立で、 μ_{ij} が以下の回帰構造で与えられる位置を持ち分散が σ_π^2 の正規分布に従うと仮定する

$$\beta_0 + \beta_1 ACT_i + \beta_2 HSR_j$$

- 超パラメータ β の分布

$\beta = (\beta_0, \beta_1, \beta_2)$ は $N_3(\bar{\beta}, \Sigma_\beta)$ に従うと仮定

$\bar{\beta}$ は、パラメータの平均、 Σ_β は分散共分散行列

階層的回帰モデル(2)

- σ_π^2 の分布

σ_π^2 は S_{Xv}^{-2} に従うと仮定する

S_{Xv}^{-2} : 自由度 v の逆カイ2乗分布

- パラメータ $(\mu, \beta, \sigma_\pi^2)$ の事後密度は以下のようにになる

$$g(\mu, \beta, \sigma_\pi^2 | y) \propto \prod_{i=1}^8 \prod_{j=1}^5 \exp\left\{-\frac{n_{ij}}{2\sigma^2} (y_{ij} - \mu_{ij})^2\right\} \times \prod_{i=1}^8 \prod_{j=1}^5 \frac{1}{\sigma_\pi} \exp\left\{-\frac{n_{ij}}{2\sigma_\pi^2} (\mu_{ij} - x_{ij}'\beta)^2\right\} \\ \times \exp\left\{-\frac{1}{2} (\beta - \bar{\beta}) \Sigma^{-1} (\beta - \bar{\beta})\right\} (\sigma_\pi^2)^{-v/2-1} \exp\left\{-\frac{S}{2\sigma_\pi^2}\right\}$$

パラメータの推定

- このモデルのパラメータ($\mu, \beta, \sigma_{\pi}^2$) の結合事後密度からシミュレーションするには、hiergibbs関数を用いる

hiergibbs関数:階層的回帰モデルでギブスサンプリングを行う

引数: dataファイル、サイクル数

```
FIT=hiergibbs(iowagpa,5000)
```

β の推定

- Bの値の分位点を求める

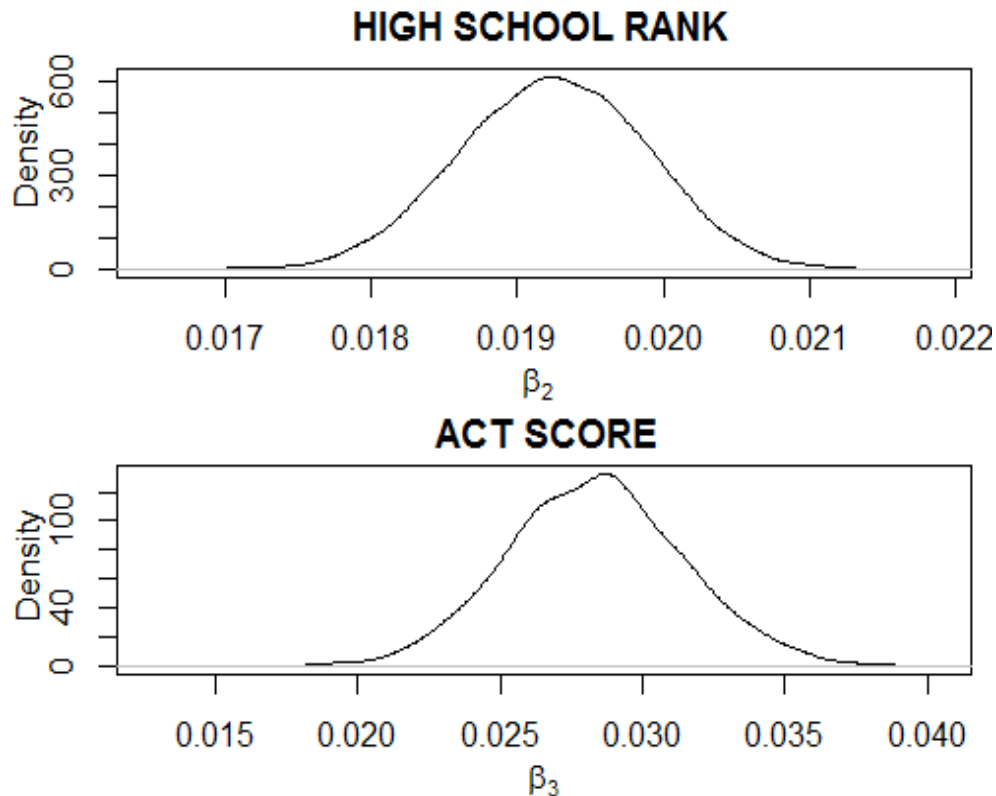
分位点を求めるにはquantile関数を用いる

```
> quantile(FIT$beta[,2],c(.025,.25,.5,.75,.975)) # $\beta_1$ の分位点を求める
  2.5%    25%    50%    75%    97.5%
0.01799428 0.01880991 0.01925748 0.01968191 0.02046982
>
> quantile(FIT$beta[,3],c(.025,.25,.5,.75,.975)) # $\beta_2$ の分位点を求める
  2.5%    25%    50%    75%    97.5%
0.02238404 0.02624022 0.02834135 0.03034493 0.03455294
>
```

- β_1 の95%区間推定値は(0.017,0.020)
- β_2 の95%区間推定値は(0.022,0.034)

β の推定(2)


```
par(mfrow=c(2,1)) ##以下、グラフを描くためのコマンド
> plot(density(FIT$beta[,2]),xlab=expression(beta[2]),
+ main="HIGH SCHOOL RANK")
> plot(density(FIT$beta[,3]),xlab=expression(beta[3]),
+ main="ACT SCORE")
```



- 階層的回帰モデルにおける回帰係数 β_2 と β_3 のシミュレーションした標本の密度推定値

GPAの事後平均を求める

- `posterior.means = apply(FIT$mu, 2, mean)` #GPAの事後平均を求める
- `> posterior.means = matrix(posterior.means, nrow = 8, ncol = 5, #以下、グラフを描くためのコマンド`
- `+ byrow = T)`
- `> par(mfrow=c(1,1))`
- `> matplot(act, t(posterior.means), type = "l", lwd = 3, lty=1:8, col=1,`
- `+ xlim = c(17, 34))`
- `> legend(30, 3, lty = 1:8, lwd = 2, legend = c("HSR=9", "HSR=8",`
- `+ "HSR=7", "HSR=6", "HSR=5", "HSR=4", "HSR=3", "HSR=2"))`



- 階層的事前モデルを使ったGPAの事後平均のプロット図

10.4.4 学生の成績を予測する

- 大学は、将来入学してくる学生の成績を予測したい

GPAの2.5以上が成功したとするならば以下の予測事後密度を計算する

$$P(z_{ij}^* \geq 2.5 | y) = \int P(z_{ij}^* \geq 2.5 | \mu, y) g(\mu | y) d\mu$$

z_{ij}^* : ACTスコアが*i*で、高校の成績ランクが*j*の学生が将来入学する大学のGPAとする

$g(\mu | y)$: セル平均のベクトル μ の事後分布

- z_{ij} の分布を正規分布 $N(\mu_{ij}, \sigma)$ に従うと仮定すると

$$P(z_{ij}^* \geq 2.5 | y) = \int \left[1 - \Phi \left(\frac{2.5 - \mu_{ij}}{\sigma} \right) \right] g(\mu | y) d\mu$$

学生の成績を予測する(2)

- 仮に $\{u_{ij}^t, t=1, \dots, m\}$ が u_{ij} の周辺事後分布から標本だとすると

$$P(z_{ij}^* \geq 2.5 | y) \approx \frac{1}{m} \sum_{t=1}^m \left[1 - \Phi \left(\frac{2.5 - \mu_{ij}^t}{\sigma} \right) \right]$$

- 予測確率を計算する

hiergibbs関数の出力はFITであるので、FIT\$muが事後分布からシミュレーションされたセル平均の行列となる

```
p=1-pnorm((2.5-FIT$mu)/.65) #上の式の[ ]内を計算する
> prob.success=apply(p,2,mean) #確率pの平均を計算する
> #以下、表を表示させるコマンド
> prob.success=matrix(prob.success,nrow=8,ncol=5,byrow=T)
> dimnames(prob.success)=list(HSR=rlabels,ACTC=clabels)
> round(prob.success,3)
```

学生の成績を予測する(3)

ACTC					
HSR	16-18	19-21	22-24	25-27	28-30
91-99	0.690	0.748	0.781	0.813	0.879
81-90	0.554	0.617	0.662	0.690	0.757
71-80	0.466	0.503	0.579	0.630	0.625
61-70	0.360	0.411	0.425	0.438	0.537
51-60	0.249	0.304	0.304	0.410	0.441
41-50	0.168	0.193	0.221	0.281	0.319
31-40	0.107	0.140	0.153	0.189	0.224
21-30	0.062	0.078	0.096	0.121	0.153

- 将来のGPAが2.5を超える予測確率