

# 統計モデリング入門 2015 (g)

階層ベイズモデル Hierarchical Bayesian Model

久保拓弥 `kubo@ees.hokudai.ac.jp`

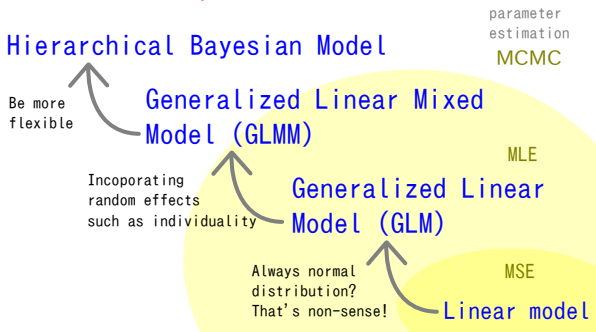
北大環境科学院の講義 <http://goo.gl/76c4i>

2015-07-29

ファイル更新時刻: 2015-07-28 22:32

# 今日は 階層ベイズモデル

The development of linear models



# 今日のハナシ

example

## ① MCMC サンプルングのための 例題

logistic regression: binomial distribution

## ② 同じような推定を MCMC でやってみる

最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

## ③ Softwares for MCMC sampling

“Gibbs sampling” などが簡単にできるような.....

## ④ GLMM と階層ベイズモデル

GLMM のベイズモデル化

estimation

## ⑤ 階層ベイズモデルの 推定

ソフトウェア JAGS を使ってみる

## ⑥ おわり

統計モデルを理解してデータ解析をする

# 1. MCMC サンプリングのための 例題 example


logistic regression: binomial distribution

and logit link function

example seed survivorship, again


## 例題：植物の種子の生存確率

- 架空植物の種子の生存を調べた
- 種子: 生きていれば発芽する
  - どの個体でも **8 個** の種子を調べた
- 生存確率: ある種子が生きている確率
- データ: 植物 **20** 個体, 合計 **160** 種子の生存の有無を調べた
- 73 種子が生きていた — このデータを統計モデル化したい



たとえばこんなデータが得られたとしましょう

個体ごとの生存数	0	1	2	3	4	5	6	7	8
観察された個体数	1	2	1	3	6	6	1	0	0



生存していた種子数  $y_i$

これは個体差なしの均質な集団

## binomial distribution

生存確率  $q$  と 二項分布 の関係

- 生存確率を推定するために**二項分布** という確率分布を使う
- 個体  $i$  の  $N_i$  種子中  $y_i$  個が生存する確率

$$p(y_i | q) = \binom{N_i}{y_i} q^{y_i} (1 - q)^{N_i - y_i},$$

- ここで仮定していること
  - **個体差はない**
  - つまり **すべての個体で同じ生存確率  $q$**

ゆうど

## 尤度: 20 個体ぶんのデータが観察される確率

- 観察データ  $\{y_i\}$  が確定しているときに
- パラメータ  $q$  は値が自由にとりうると考える  
likelihood
- 尤度 は 20 個体ぶんのデータが得られる確率の積, パラメータ  $q$  の関数として定義される

$$L(q|\{y_i\}) = \prod_{i=1}^{20} p(y_i | q)$$

---

個体ごとの生存数	0	1	2	3	4	5	6	7	8
観察された個体数	1	2	1	3	6	6	1	0	0

---



## 対数尤度方程式と最尤推定

- この尤度  $L(q \mid \text{データ})$  を最大化するパラメータの推定量  $\hat{q}$  を計算したい
- 尤度を対数尤度になおすと

$$\begin{aligned}\log L(q \mid \text{データ}) &= \sum_{i=1}^{20} \log \binom{N_i}{y_i} \\ &+ \sum_{i=1}^{20} \{y_i \log(q) + (N_i - y_i) \log(1 - q)\}\end{aligned}$$


- この対数尤度を最大化するように未知パラメーター  $q$  の値を決めてやるのが**最尤推定**

## maximum likelihood estimation

## 最尤推定 (MLE) とは何か


- 対数尤度  $L(q \mid \text{データ})$  が最大になるパラメーター  $q$  の値をさがすこと
- 対数尤度  $\log L(q \mid \text{データ})$  を  $q$  で偏微分して 0 となる  $\hat{q}$  が対数尤度最大
$$\partial \log L(q \mid \text{データ}) / \partial q = 0$$
- 生存確率  $q$  が全個体共通の場合の最尤推定量・最尤推定値は

$$\hat{q} = \frac{\text{生存種子数}}{\text{調査種子数}} = \frac{73}{160} = 0.456 \text{ ぐらい}$$



二項分布で説明できる 8 種子中  $y_i$  個の生存

$$\hat{q} = 0.46 \text{ なので } \binom{8}{y} 0.46^y 0.54^{8-y}$$



## 2. 同じような推定を MCMC でやってみる

最尤推定と Markov chain Monte Carlo (MCMC) はちがう!

そして “なんとなく” ベイズ統計モデルと関連づけ

## ここでやること: 尤度と MCMC の関係を考える


- さきほどの簡単な例題 (生存確率) のデータ解析を
- 最尤推定ではなく
- Markov chain Monte Carlo (MCMC) 法のひとつである**メトロポリス法** (Metropolis method) であつかう
- 得られる結果: 「パラメーターの値の分布」.....??

MCMC をもちださなくてもいい簡単すぎる問題  
説明のためあえてメトロポリス法を適用してみる

# メトロポリス法を説明するための準備


連続的な対数尤度関数

$\log L(q)$



離散化:  $q$  がとびとびの値を

とる




説明を簡単にするため

生存確率  $q$  の軸を離散化する

(実際には離散化する必要などない)

## 試行錯誤による $q$ の最尤推定値の探索

### ちょっと効率の悪い「試行錯誤の最尤推定」



- ①  $q$  の値の「行き先」を「両隣」どちらかにランダムに決める
- ② 「行き先」が現在の尤度より高ければ、 $q$  の値をそちらに変更
- ③ 尤度が変化しなくなるまで (1), (2) をくりかえす

## メトロポリス法のルール: この例題の場合

### ① パラメーター $q$ の初期値を選ぶ

(ここでは  $q$  の初期値が 0.3)

### ② $q$ を増やすか減らすかをランダムに決める

(新しく選んだ  $q$  の値を  $q_{\text{new}}$  としましょう)

### ③ $q_{\text{new}}$ における尤度 $L(q_{\text{new}})$ ともとの尤度 $L(q)$ を比較

- $L(q_{\text{new}}) \geq L(q)$  (あてはまり改善):  $q \leftarrow q_{\text{new}}$
- $L(q_{\text{new}}) < L(q)$  (あてはまり改悪):
  - 確率  $r = L(q_{\text{new}})/L(q)$  で  $q \leftarrow q_{\text{new}}$
  - 確率  $1 - r$  で  $q$  を変更しない

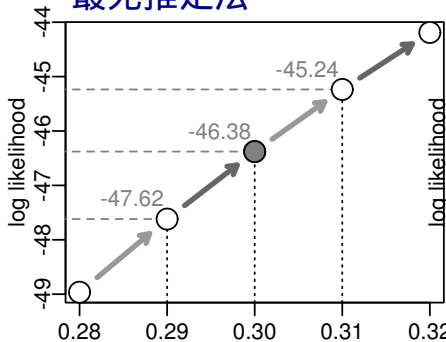
### ④ 手順 2. にもどる

( $q = 0.01$  や  $q = 0.99$  でどうなるんだ, といった問題は省略)




# メトロポリス法のルールで $q$ を動かす

## 最尤推定法



## メトロポリス法 (MCMC)




メトロポリス法だと

「単調な山のぼり」にはならない

対数尤度関数の「山」でうろうろする  $q$  の値


メトロポリス法 (そして一般の MCMC) は  
最適化ではない



ときどきはでに落っこちる

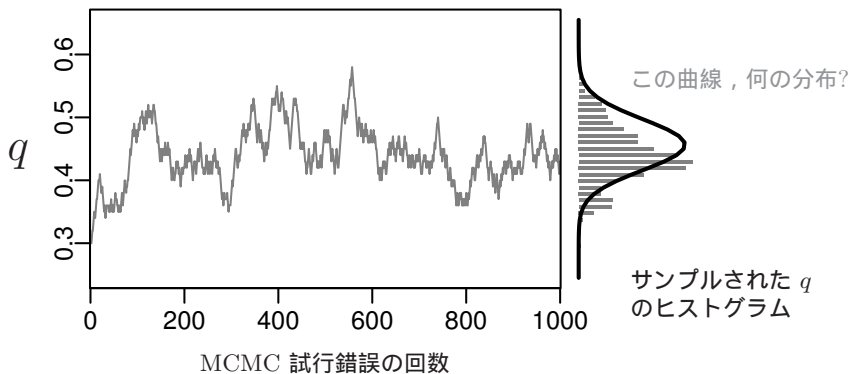
何のためにこんなことをやるのか?

$q$  の変化していく様子を記録してみよう

ステップごとに  $q$  の値をサンプリング

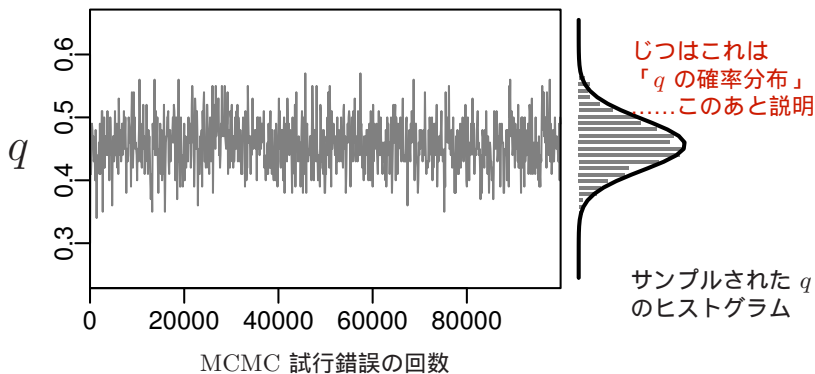
もっと試行錯誤してみたほうがいいのか?

# もっと長くサンプリングしてみる





まだまだ.....?

# もっともっと長くサンプリングしてみる



なんだか、ある「山」のかたちにとまとまったぞ?


## MCMC は何をサンプリングしている?

対数尤度  $\log L(q)$ 尤度  $L(q)$  に  
比例する確率分布

尤度に比例する確率分布からのランダムサンプル

マルコフ連鎖の定常分布は  $p(q) = \frac{L(q)}{\sum_q L(q)}$  となる

# MCMC の結果として得られた $q$ の経験分布



- データと統計モデル (二項分布) を決めて, MCMC サンプルングすると,  $p(q)$  からのランダムサンプルが得られる
- このランダムサンプルをもとに,  $q$  の平均や 95% 区間などがわかる — **便利じゃないか!**

MCMC という推定方法から  
「パラメーター  $q$  の確率分布」  
というちょっと奇妙な考えかたが  
でてきた .....



「ふつう」の統計学では  
「パラメーターの確率分布」といった  
考えかたはしない, しかし .....

ベイズ統計学なら  
「パラメーターの確率分布」はぜんぜん  
自然な考えかただ

## ベイズモデル: 尤度・事後分布・事前分布.....


- ベイズの公式  $p(q | \mathbf{Y}) = \frac{p(\mathbf{Y} | q) \times p(q)}{p(\mathbf{Y})}$
- $p(q | \mathbf{Y})$  は何かデータ ( $\mathbf{Y}$ ) のもとで何かパラメーター ( $q$ ) が得られる確率 (事後分布)
- $p(q)$  はあるパラメーター  $q$  が得られる確率 (事前分布)
- $p(\mathbf{Y} | q)$  パラメーターを決めたときにデータが得られる確率 (尤度に比例)
- $p(\mathbf{Y})$  はデータ  $\mathbf{Y}$  が得られる確率 (単なる規格化定数)

$$(\text{事後分布}) \propto \frac{\text{尤度} \times \text{事前分布}}{(\text{データが得られる確率})}$$

$$\propto \text{尤度} \times \text{事前分布}$$

# ベイズ統計にむりやりこじつけてみると?

$q$  の事前分布は一様分布 , と考えるとつじつまがあう?



事前分布ってのがよくわからない.....

以上の説明は、  
「MCMC によって得られる結果」  
は  
「ベイズ統計でいうパラメーターの事後分布」  
と考えると解釈しやすいかも  
といったことを  
ばくぜんかつなんとなく対応づける  
ひとつのこころみでありました……

厳密な正当化とかそういったものではありません

### 3. Softwares for MCMC sampling

“Gibbs sampling” などが簡単にできるような.....

事後分布から効率よくサンプリングしたい

# 統計ソフトウェア R

<http://www.r-project.org/>



## 簡単な GLMM なら R だけで推定可能

今回の例題の事後分布 ( $\mathbf{Y} = \{y_i\}$  はデータ)

$$p(a, \{r_i\}, s | \mathbf{Y}) \propto \prod_{i=1}^{100} p(y_i | q(a + r_i)) p(a) p(r_i | s) p(s)$$

積分で「個体差」  $r_i$  を消して，周辺尤度を定義する

$$L(a, s | \mathbf{Y}) = \prod_{i=1}^{100} \int_{-\infty}^{\infty} p(y_i | q(a + r_i)) p(r_i | s) dr_i$$

これを最大化する  $\hat{a}$  と  $\hat{s}$  を推定すればよい


— 経験ベイズ法 (empirical Bayesian method)



## しかし、「R だけ」では限界があるかも

- R にはいろいろな GLMM の最尤推定関数が準備されている .....
- `library(glmmML)` の `glmmML()`
- `library(lme4)` の `lmer()`
- `library(nlme)` の `nlme()` (正規分布のみ)
- しかし もうちょっと複雑な GLMM , たとえば個体差 + 地域差をいれた統計モデルの最尤推定はかなり難しい (ヘンな結果が得られたりする)
- 積分がたくさん入っている尤度関数の評価がしんどい

そこで MCMC による事後分布からのサンプリング!




生存確率  $q$

アルゴリズムにしたがって  
乱数を発生させていくだけで OK

## 再確認: 「事後分布からのサンプル」って何の役にたつの?

```
> post.mcmc[,"a"] # 事後分布からのサンプルを表示
[1] -0.7592 -0.7689 -0.9008 -1.0160 -0.8439 -1.0380 -0.8561 -0.9837
[9] -0.8043 -0.8956 -0.9243 -0.9861 -0.7943 -0.8194 -0.9006 -0.9513
[17] -0.7565 -1.1120 -1.0430 -1.1730 -0.6926 -0.8742 -0.8228 -1.0440
... (以下略) ...
```

これらのサンプルの平均値・中央値・95% 区間を  
調べることで事後分布の概要がわかる



## どのようなソフトウェアで MCMC 計算するか?

### ① 自作プログラム

- 利点: 問題にあわせて自由に設計できる
- 欠点: 階層ベイズモデル用の MCMC プログラミング, けっこうめんどう

### ② R のベイズな package

- 利点: 空間ベイズ統計など便利な専用 package がある
- 欠点: 汎用性, とぼしい

### ③ “BUGS” で “Gibbs sampler” なソフトウェア

- 利点: 幅ひろい問題に適用できて, 便利
- 欠点というほどでもないけど, 多少の勉強が必要
- えーっと “Gibbs sampler” って何?

# さまざまな MCMC アルゴリズム

## いろいろな MCMC


- **メトロポリス法**: 試行錯誤で値を変化させていく MCMC
  - メトロポリス・ヘイスティングス法: その改良版
- **ギブス・サンプリング**: 条件つき確率分布を使った MCMC
  - 複数の変数 (パラメーター・状態) を効率よくサンプリング

# Gibbs sampling とは何か?

- MCMC アルゴリズムのひとつ
- 複数のパラメーターの MCMC サンプリングに使う
- 例: パラメーター  $\beta_1$  と  $\beta_2$  の Gibbs sampling
  - ①  $\beta_2$  に何か適当な値を与える
  - ②  $\beta_2$  の値はそのままにして, その条件のもとでの  $\beta_1$  の MCMC sampling をする (条件つき事後分布)
  - ③  $\beta_1$  の値はそのままにして, その条件のもとでの  $\beta_2$  の MCMC sampling をする (条件つき事後分布)
  - ④ 2. - 3. をくりかえす
- 教科書の第 9 章の例題で説明

# 図解: Gibbs sampling (統計モデリング入門の第9章)

MCMC  $\beta_1$  のサンプリング  $\beta_2$  のサンプリング



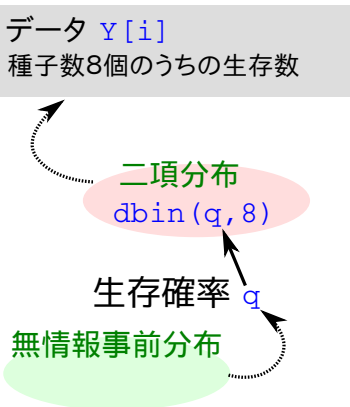
## 便利な “BUGS” 汎用 Gibbs sampler たち

- BUGS 言語 (+ っぽいもの) でベイズモデルを記述できるソフトウェア
  - WinBUGS — **ありがとう**, さようなら?
  - OpenBUGS — 予算が足りなくて停滞?
  - **JAGS** — お手軽で良い, どんな OS でも動く
  - Stan — たぶん “次” はこれ  
— 今日は紹介しませんか .....
- リンク集: <http://hosho.ees.hokudai.ac.jp/~kubo/ce/BayesianMcmc.html>

えーと.....BUGS 言語って何?



## このベイズモデルを BUGS 言語で記述したい



## BUGS 言語コード

```
for (i in 1:N.sample) {
  Y[i] ~ dbin(q, 8)
}
q ~ dunif(0.0, 1.0)
```

矢印は手順ではなく，依存関係をあらわしている

BUGS 言語: ベイズモデルを記述する言語

Spiegelhalter et al. 1995. BUGS: Bayesian Using Gibbs Sampling version 0.50.

## なんとなく使われ続けている WinBUGS 1.4.3

- おそらく世界でもっともよく使われている Gibbs sampler
- **BUGS** 言語の実装
- 2004-09-13 に最新版（ここで開発停止 → OpenBUGS）
- ソースなど非公開，無料，ユーザー登録**不要**
- Windows バイナリーとして配布されている
  
- 歴史を変えたソフトウェアだけど，開発も停止していることだし，まあ，もう“ごくろうさま”ということで.....

## いろいろな OS で使える JAGS3.4.0

- R core team のひとり Martyn Plummer さんが開発
  - Just Another Gibbs Sampler
- C++ で実装されている
  - R がインストールされていることが必要
- Linux, Windows, Mac OS X バイナリ版もある
- ざりざりと開発進行中
- R からの使う: `library(rjags)`

## R から JAGS にこんなかんじで仕事を命じる (1 / 3)

```
library(rjags)
library(R2WinBUGS) # to use write.model()

model.bugs <- function()
{
  for (i in 1:N.data) {
    Y[i] ~ dbin(q, 8) # 二項分布にしたがう
  }
  q ~ dunif(0.0, 1.0) # q の事前分布は一様分布
}

file.model <- "model.bug.txt"
write.model(model.bugs, file.model) # ファイル出力

# 次につづく.....
```

## R から JAGS にこんなかんじで仕事を命じる (2 / 3)

```
load("data.RData")
list.data <- list(Y = data, N.data = length(data))
inits <- list(q = 0.5)
n.burnin <- 1000
n.chain <- 3
n.thin <- 1
n.iter <- n.thin * 1000

model <- jags.model(
  file = file.model, data = list.data,
  inits = inits, n.chain = n.chain
)
```

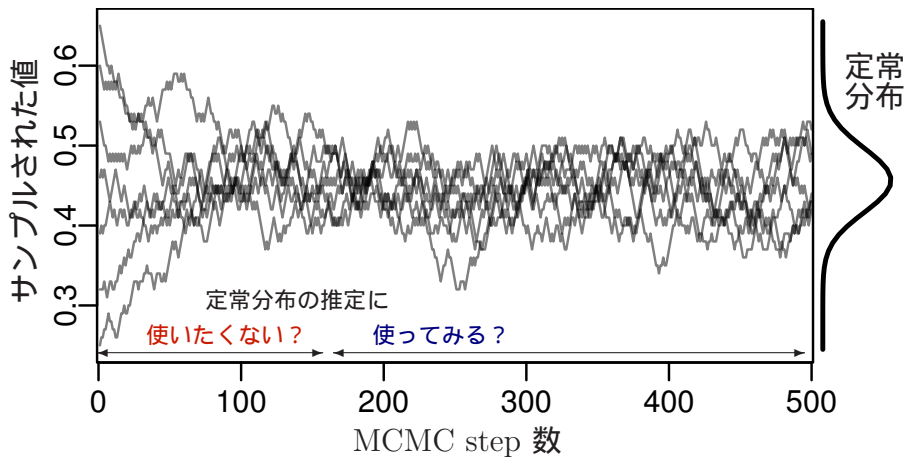
```
# まだ次につづく.....
```

## R から JAGS にこんなかんじで仕事を命じる (3 / 3)

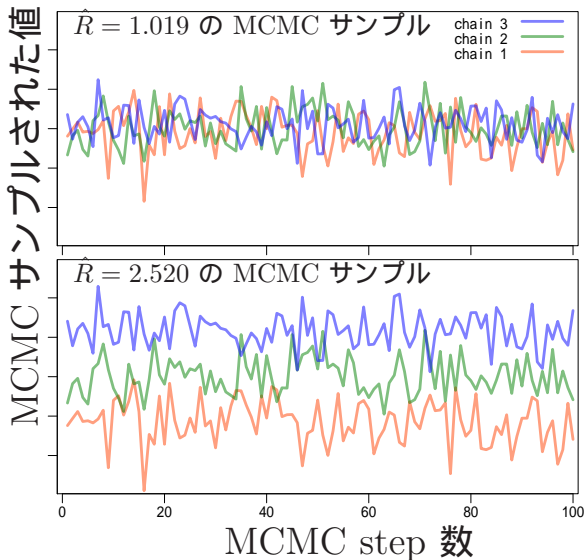
```
# burn-in
update(model, n.burnin) # burn in

# サンプリング結果を post.mcmc.list に格納
post.mcmc.list <- coda.samples(
  model = model,
  variable.names = names(inits),
  n.iter = n.iter,
  thin = n.thin
)
# おわり
```

burn in って何? → 「使いたくない」長さの指定



## 試行間で差がないかを「診断」する



まあ、  
いいかな.....

何やら  
問題あり!




## 収束診断の $\hat{R}$ 指数

- `gelman.diag(post.mcmc.list)` → 実演表示
- $\hat{R}$  は Gelman-Rubin の収束判定用の指数
  - $\hat{R} = \sqrt{\frac{\hat{\text{var}}^+(\psi|y)}{W}}$
  - $\hat{\text{var}}^+(\psi|y) = \frac{n-1}{n}W + \frac{1}{n}B$
  - $W$  : サンプル列内の variance の平均
  - $B$  : サンプル列間の variance
  - Gelman et al. 2004. Bayesian Data Analysis. Chapman & Hall/CRC


# Gibbs sampling → 事後分布の推定

- `plot(post.mcmc.list)`

### Trace of q



### Density of q




## 4. GLMM と階層ベイズモデル

### GLMM のベイズモデル化

hierarchical Bayesian  
階層ベイズモデルとなる

## 二項分布では説明できない観測データ!


100 個体の植物の合計 800 種子中 **403 個** の生存が見られたので，平均生存確率は 0.50 と推定されたが.....



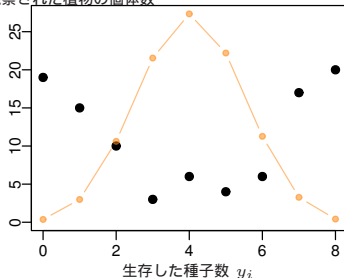
さっきの例題と同じようなデータなのに?  
 (「統計モデリング入門」第 10 章の最初の例題)

# 個体差 → 過分散 (overdispersion)

## 極端な過分散の例



観察された植物の個体数



- 種子全体の平均生存確率は 0.5 ぐらいかもしれないが.....
- 植物個体ごとに種子の生存確率が異なる: 「個体差」
- 「個体差」があると overdispersion が生じる
- 「個体差」の原因は観測できない・観測されていない

## モデリングやりなおし: 個体差を考慮する


- 生存確率を推定するために **二項分布** という確率分布を使う
- 個体  $i$  の  $N_i$  種子中  $y_i$  個が生存する確率は二項分布

$$p(y_i | q_i) = \binom{N_i}{y_i} q_i^{y_i} (1 - q_i)^{N_i - y_i},$$

- ここで仮定していること
  - **個体差がある** ので個体ごとに生存確率  $q_i$  が異なる

## GLM わざ: ロジスティック関数で表現する生存確率

- 生存確率  $q_i = q(z_i)$  をロジスティック関数  $q(z) = 1/\{1 + \exp(-z)\}$  で表現



- 線形予測子  $z_i = a + r_i$  とする
  - パラメーター  $a$ : 全体の平均
  - パラメーター  $r_i$ : 個体  $i$  の個体差 (ずれ)

## 個々の個体差 $r_i$ を最尤推定するのはまずい


- 100 個体の生存確率を推定するためにパラメーター **101 個** ( $a$  と  $\{r_1, r_2, \dots, r_{100}\}$ ) を推定すると.....
- 個体ごとに生存数 / 種子数を計算していることと同じ! (「データのよみあげ」と同じ)

そこで、次のように考えてみる



suppose  $\{r_i\}$  follow the Gaussian distribution

$\{r_i\}$  のばらつきは正規分布だと考えてみる




$$p(r_i | s) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{r_i^2}{2s^2}\right)$$

この確率密度  $p(r_i | s)$  は  $r_i$  の「出現しやすさ」をあらわしていると解釈すればよいでしょう。  $r_i$  がゼロにちかい個体はわりと「ありがち」で、  $r_i$  の絶対値が大きな個体は相対的に「あまりいない」。


ひとつの例示: 個体差  $r_i$  の分布と過分散の関係

(A) 個体差のばらつきが小さい場合


(B) 個体差のばらつきが大きい場合




$p(r_i|s)$  が生成した  
50 個体ぶんの  $\{r_i\}$



確率  $q_i = \frac{1}{1+\exp(-r_i)}$   
の二項乱数を発生させる




$p(y_i|q_i)$  が  
生成した生  
存種子数の  
一例



# これは $r_i$ の事前分布の指定，ということ

前回の授業で  $\{r_i\}$  は正規分布にしたがうと仮定したが  
ベイズ統計モデリングでは「**100 個の  $r_i$  たちに  
共通する事前分布として正規分布**を指定した」  
ということになる




$$p(r_i | s) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{r_i^2}{2s^2}\right)$$

## ベイズ統計モデルでよく使われる三種類の事前分布

たいていのベイズ統計モデルでは、ひとつのモデルの中で複数の種類の事前分布を混ぜて使用する。


(A) 主観的な事前分布

(できれば使いたくない!)




(B) 無情報事前分布

わからない?



(C) 階層事前分布


$s$  によって  
変わる...



# $r_i$ の事前分布として階層事前分布を指定する

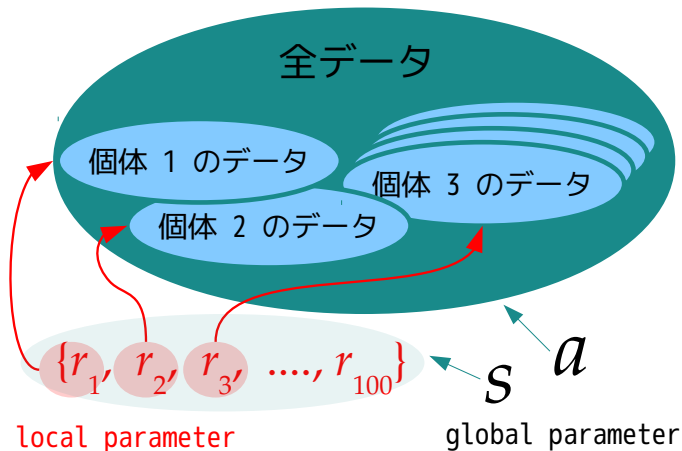
## 階層事前分布の利点

「データにあわせて」事前分布が変形!



$$p(r_i | s) = \frac{1}{\sqrt{2\pi s^2}} \exp\left(-\frac{r_i^2}{2s^2}\right)$$


## 統計モデルの大域的・局所的なパラメーター




データのどの部分を説明しているのか?

# パラメーターごとに適切な事前分布を選ぶ

(B) 無情報事前分布



(C) 階層事前分布



パラメーターの  
種類

説明する範囲

事前分布

全体に共通する平均・ばらつき

global  
大域的


無情報事前分布

個体・グループごとのずれ

local  
局所的


階層事前分布

# 個体差 $\{r_i\}$ のばらつき $s$ の無情報事前分布



- $s$  はどのような値をとってもかまわない
- そこで  $s$  の事前分布は **無情報事前分布** (non-informative prior) とする
- たとえば一様分布, ここでは  $0 < s < 10^4$  の一様分布としてみる




全個体の「切片」 $a$  の無情報事前分布

「生存確率の (logit) 平均  $a$  は何でもよい」と表現している

# 階層ベイズモデル: 事前分布の階層性

超事前分布 → 事前分布という階層があるから

データ 種子8個のうち  
 $y[i]$  が生存



矢印は手順ではなく、依存関係をあらわしている

## 6. 階層ベイズモデルの <sup>estimation</sup> 推定

ソフトウェア JAGS を試してみる

R の “したうけ” として JAGS を使う


## 階層ベイズモデルを BUGS コードで記述する

```

model
{
  for (i in 1:N.data) {
    Y[i] ~ dbin(q[i], 8)
    logit(q[i]) <- a + r[i]
  }
  a ~ dnorm(0, 1.0E-4)
  for (i in 1:N.data) {
    r[i] ~ dnorm(0, tau)
  }
  tau <- 1 / (s * s)
  s ~ dunif(0, 1.0E+4)
}

```


データ 種子8個のうち  
Y[i] が生存




## JAGS で得られた事後分布サンプルの要約

```
> source("mcmc.list2bugs.R") # なんとなく便利なので...
> post.bugs <- mcmc.list2bugs(post.mcmc.list) # bugs クラスに変換
```

3 chains, each with 4000 iterations (first 2000 discarded)



medians and 80% intervals



## bugs オブジェクトの post.bugs を調べる


- `print(post.bugs, digits.summary = 3)`
- 事後分布の 95% 信頼区間などが表示される

```
3 chains, each with 4000 iterations (first 2000 discarded), n.thin = 2
n.sims = 3000 iterations saved
```


	mean	sd	2.5%	25%	50%	75%	97.5%	Rhat	n.eff
a	0.020	0.321	-0.618	-0.190	0.028	0.236	0.651	1.007	380
s	3.015	0.359	2.406	2.757	2.990	3.235	3.749	1.002	1200
r[1]	-3.778	1.713	-7.619	-4.763	-3.524	-2.568	-1.062	1.001	3000
r[2]	-1.147	0.885	-2.997	-1.700	-1.118	-0.531	0.464	1.001	3000
r[3]	2.014	1.074	0.203	1.282	1.923	2.648	4.410	1.001	3000
r[4]	3.765	1.722	0.998	2.533	3.558	4.840	7.592	1.001	3000
r[5]	-2.108	1.111	-4.480	-2.775	-2.047	-1.342	-0.164	1.001	2300
...	(中略)								
r[99]	2.054	1.103	0.184	1.270	1.996	2.716	4.414	1.001	3000
r[100]	-3.828	1.766	-7.993	-4.829	-3.544	-2.588	-1.082	1.002	1100

## 各パラメーターの事後分布サンプルを R で調べる


Trace of a




Density of a



Trace of s




Density of s



## 得られた事後分布サンプルを組みあわせて予測

- `post.mcmc <- to.mcmc(post.bugs)`
- これは `matrix` と同じようにあつかえるので、作図に便利



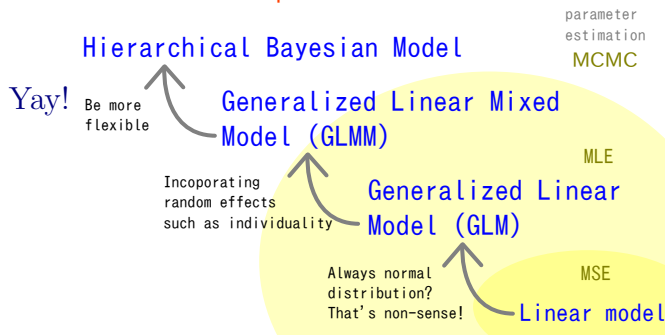


## 6. おわり

統計モデルを理解してデータ解析をする

# ここでひとまず**統計モデリング** 授業は終了

## The development of linear models



- データ解析の背後には統計モデルがある
- 統計モデルを理解して使おう
- データにあわせて統計モデルを設計する