

2011-04-20

「生態系機能学総論」の一部:  
生態学の統計モデリング (2011 年 4-5 月) 投影資料  
全部で 7 回講義の 4 回目

# 階層ベイズモデルの基礎 (1)

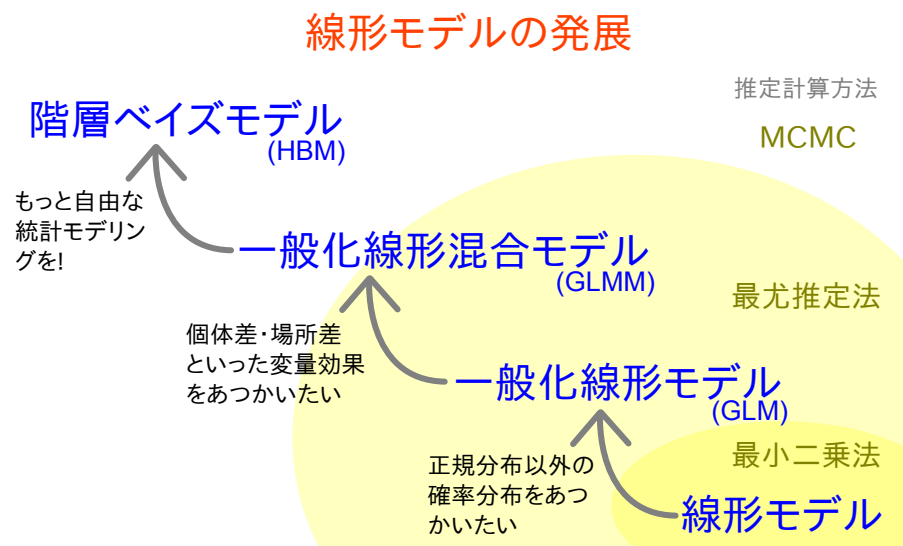
## 個体差のモデリング

久保拓弥 [kubo@ees.hokudai.ac.jp](mailto:kubo@ees.hokudai.ac.jp)

<http://goo.gl/Brd9g>

# 今回と次回で説明しようとすること

- パラメーターをどうやって推定するか?
  - 最尤推定 → Markov chain Monte Carlo (MCMC)
- 一般化線形モデル → 階層ベイズモデル
  - より現実的・実戦的なデータ解析のために



# 階層ベイズモデル・MCMC の基礎

## 今回:

最尤推定って何?

MCMC によるパラメーター推定?

階層ベイズモデルとは何か?

## 次回:

階層ベイズモデルを推定するソフトウェアは?

R とどうやって連動させるか?

# このあとの統計モデル化の説明の手順

## 1. 簡単な例題: GLM でうまくいく場合

- 統計モデルの部品: 二項分布モデル (GLM)
- 統計モデルの推定方法: 最尤推定法

## 2. MCMC とベイズモデリング

- 最尤推定を MCMC におきかえてみる
- MCMC で得られた結果をベイズ的に解釈


## 3. ちょっと難しい例題: GLM でうまくいかない場合

- 「個体全体の平均」と「個体差」をどうあつかう?
- 階層ベイズモデル!

本日の例題: 植物の種子と二項分布  
パラメーターの最尤推定とは何か?


# 繁殖生態学の例題: 架空植物の生存確率

- 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 100 個体, 合計 800 種子の生存の有無を調べた
- 問: この植物の生存確率はどのように統計モデル化できるか?



# 簡単な例題: 生存確率は全個体で同じ (「個体差」なし)

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	0	5	8	21	29	22	12	2	1



# 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  $y_i$  個が生存する確率は二項分布


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

- 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  $q$**



## 二項分布で「 $N_i$ 個中の $y_i$ 個」型データをあつかう

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



# 尤度: 100 個体ぶんのデータが観察される確率

- 観察データ  $\{y_i\}$  が与えられたもので, パラメータ  $q$  は値が自由にとりうると考える
- この 100 個体ぶんの確率はパラメータ  $q$  の関数として定義される

$$L(q | \text{全 } y_i) = \prod_{i=1}^{100} f(y_i | q)$$

---

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	0	5	8	21	29	22	12	2	1

---

# 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

$$\begin{aligned} \log L(q \mid \text{データ}) &= \sum_{i=1}^{100} \log \binom{N_i}{y_i} \\ &+ \sum_{i=1}^{100} \{y_i \log(q) + (N_i - y_i) \log(1 - q)\} \end{aligned}$$

- 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**


# 最尤推定とは何か

- 対数尤度  $L(q \mid \text{データ})$  が最大になるパラメーター  $q$  の値をさがしだすこと
- 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

$$\hat{q} = \frac{\text{生存種子数}}{\text{調査種子数}} = \frac{404}{800} = 0.505$$

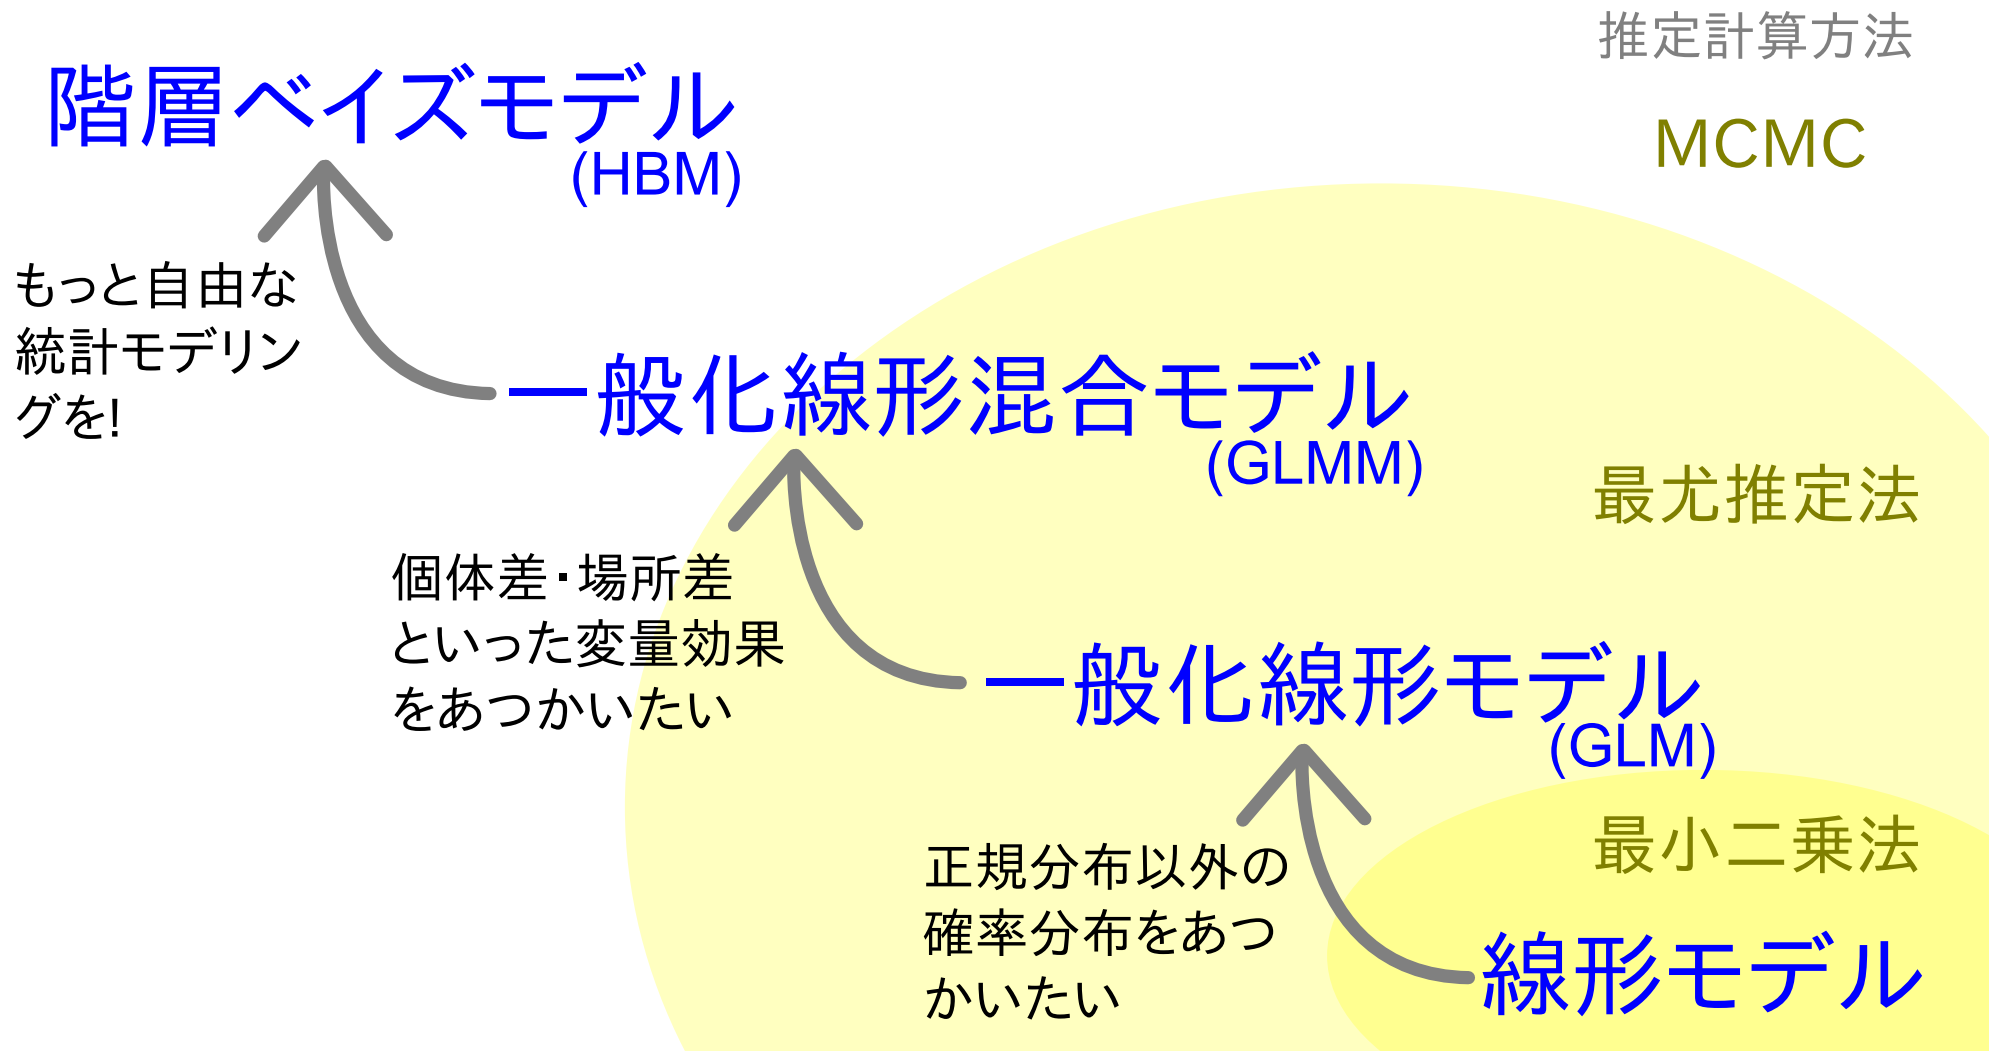


# 二項分布で説明された 8 種子中 $y_i$ 個の生存

$$\hat{q} = 0.505 \text{ なので } \binom{8}{y} 0.505^y 0.495^{8-y}$$




# 線形モデルの発展



# ロジスティック関数で表現する生存確率

- そこで生存する確率  $q_i = q(z_i)$  をロジスティック (logistic) 関数  $q(z) = 1 / \{1 + \exp(-z)\}$  で表現



- 線形予測子  $z_i = a$  (切片だけ) とする

# ちょっと整理: logistic と logit

- logistic 関数

$$q = \frac{1}{1 + \exp(-(a + bx))} = \text{logistic}(a + bx)$$

- logit 変換

$$\text{logit}(q) = \log \frac{q}{1 - q} = a + bx$$

logit は logistic の逆関数 , logistic は logit の逆関数



## R の glm() によるロジスティック回帰

```
> glm(cbind(y, 8 - y) ~ 1, family = binomial, data = d1)
```

```
... (一部略) ...
```

```
Coefficients:
```

```
(Intercept)
```

```
0.02
```

```
Degrees of Freedom: 99 Total (i.e. Null); 99 Residual
```

```
Null Deviance: 110
```

```
Residual Deviance: 110 AIC: 356
```

```
> 1 / (1 + exp(-0.02))
```

```
[1] 0.505
```

# ロジスティック回帰の `glm()` 指定

- `family`: `binomial`, 二項分布
- `link` 関数: `"logit"`
- モデル式 (線形予測子  $z$ ): たとえば  $y \sim x$  と指定

- 線形予測子  $z = a + bx$

$a, b$  は推定すべきパラメーター

- 事象の生起確率 を  $q$  とすると  $\text{logit}(q) = z$

$$\text{つまり } q = \frac{1}{\exp(-z) + 1} = \frac{1}{1 + \exp(-(a + bx))}$$

- 応答変数 は確率  $q$  でサイズ  $N$  の二項分布に従う:

$$y \sim \text{Binom}(q, N)$$

より現実的で複雑な統計モデルの  
パラメーター推定のため

最尤推定ではなく MCMC で生存確率  $q$   
を推定する — パラメーター  $q$  の確率分布?


## 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
- 試行錯誤な MCMC 法である **メトロポリス** 法であつかう
- 得られる結果: パラメーターの分布?


あえて MCMC をもちださなくてもいい問題に関して  
メトロポリス法を適用してみて,  
その挙動だの得られる結果だのをながめてみる

# 数値的に試行錯誤するパラメーター推定

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



(簡単のため, 生存確率  $q$  の軸を離散化する)

# メトロポリス法で $q$ を変化させていく

メトロポリス法は MCMC アルゴリズムのひとつ (cf. 伊庭さんの解説)



( $q$  の初期値を 0.425 , ランダムウォークで移動先を選ぶ)

## (補足) この例題のメトロポリス法

### 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 0.425)

### 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  $q_{\text{新}}$  としましょう)


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

- $L(q_{\text{新}}) \geq L(q)$  (あてはまり改善):  $q \leftarrow q_{\text{新}}$
- $L(q_{\text{新}}) < L(q)$  (あてはまり改悪):
  - 確率  $r = L(q_{\text{新}})/L(q)$  で  $q \leftarrow q_{\text{新}}$
  - 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)

# 対数尤度関数上での生存確率 $q$ の変化






# MCMC ステップにそった $q$ の変化




右側は  $q$  のヒストグラム

# 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




ターゲットとなる「パラメーターの分布」に近づいてきた

# MCMCは何をサンプリングしている？

既出の対数尤度  $\log L(q)$



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

(「パラメーターの分布」と仮称)

「マルコフ連鎖の収束定理」のおかげ (cf. 伊庭さんの説明)


# MCMC の結果として得られた「 $q$ の分布」



- データからえられる推定結果としては有用: 分布の平均や区間推定など
- 「パラメーターの分布」 ..... ベイズ統計でいうところの事後分布

# いったん整理: 尤度と MCMC の関係

- 統計モデルを作ると, あるデータのもとでの**尤度**が定義される
- この尤度に対して MCMC すると「尤度に比例する**パラメーターの分布**」からのランダムサンプルがえられる
- ベイズとの関連: これは**事後分布**からのサンプリングである



# いったん整理: いろいろな MCMC の方法

- **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・サンプラー**: 条件つき確率分布を使った MCMC
    - 普通は複数の変数 (パラメーター・状態) のサンプリングのためにもちいる (あとでこの例題にそった簡単な説明)
- 
- メトロポリス法で説明したけれどギブス・サンプラーでも同じことが言える
  - ここからあとで登場する MCMC はギブス・サンプラーと考えてください

# ベイズモデル: 尤度・事後分布・事前分布.....

- ベイズの公式 
$$p(q | Y) = \frac{p(Y | q) \times p(q)}{p(Y)}$$
- $p(q | Y)$  は何かデータ ( $Y$ ) 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)
- $p(Y | q)$  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)
- $p(Y)$  はデータ  $Y$  が得られる確率 (単なる規格化定数)


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




# 現在の例題で仮定している事前分布

$q$  の事前分布は一様分布，と考えるとつじつまがあう？


$q$  の事後分布  
(posterior)



$q$  の尤度  
(likelihood)



$q$  の事前分布  
(prior)



$\propto$

$\times$

このように「 $q$  はどんな値でもいいんですよ」という気分を表現するための事前分布が**無情報事前分布** (non-informative prior)


ちょっと難しい例題:

個体差が大きくて GLM がうまくいかない

階層ベイズモデルが必要になる状況

# また別の観測データ: 二項分布だめだめ?!



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?

# 「個体差」 → 過分散 (overdispersion)

## 極端な過分散の例




- 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: ?

## あのー …… 「個体差」とは?

- 生物学的には明確な定義はない
- しかしデータ解析においては人間が主観的に「これは個体差由来の効果であり、観察されたパターンに影響している」と定義、そして以下の二種類を区別する:
  1. fixed effects 的な効果
  2. random effects 的な効果
    - これって何なの?

## 「個体差」の fixed だの random だの ..... って何?

- 「個体ごとに異なる何かに由来する効果」を fixed/random effects にわけて統計モデリングする:
  1. fixed effects 的な効果: **観測者がわざわざ設定・測定した**要因 (実験処理, 植物のサイズなど), logit 変換された世界において生存確率の「効果の大きさ」を変える
    - この例題では fixed effects 的な要因なし
  2. random effects 的な効果: fixed effects 的ではない要因 (観測対象個体に関連する, **人間が設定・測定していないすべて**)
    - logit 変換された世界において生存確率の「効果の大きさ」を変えずにばらつきだけを変えろと考える






今回の例題では random effects な  
「個体差」だけをあつかう (説明変数なし)

# やっぱりよくわからない?

パラメーターごとに設定してやる**事前分布の種類**(あとで説明するベイズ統計モデリング)にもとづいて考えたほうが、わかりやすいかも?

(A) 主観的な事前分布 (B) 無情報事前分布 (C) 階層的な事前分布

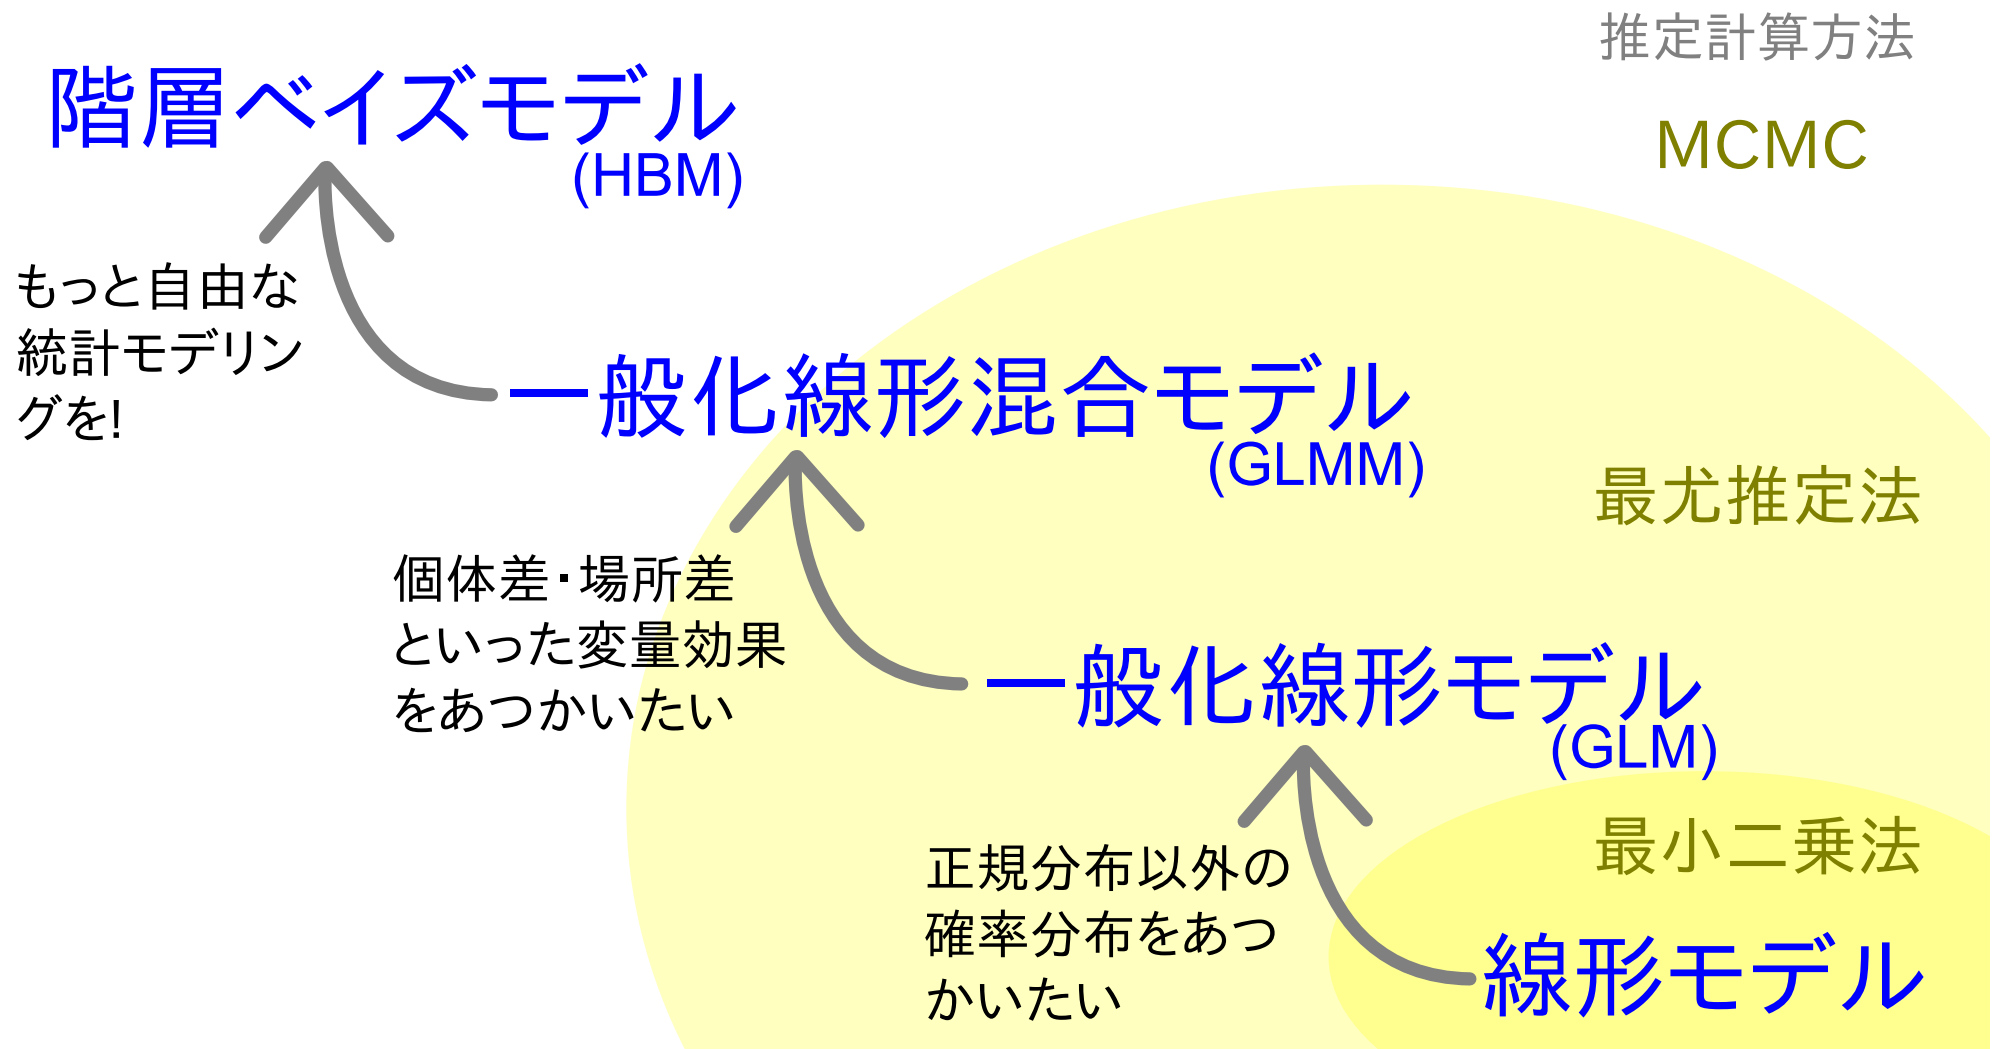


このパラメーターの事前分布は

どう設定するのが妥当だろうか、と検討する

ちょっとまた線形モデルのたぐいについて整理してみましよう.....

## 線形モデルの発展





# モデリングやりなおし: まず二項分布の再検討


- 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**
  - 個体ごとに異なる生存確率  $q_i$

# ロジスティック関数で表現する生存確率

- そこで生存する確率  $q_i = q(z_i)$  をロジスティック (logistic) 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)
- こう仮定すると問題がうまくあつかえないだろうか?
  - 個体間の生存確率はばらつくけど, そんなにすごく異ならない?
  - 観測データを使って, 「個体差」にみられるパターンを抽出したい (統計モデル化)

# 階層ベイズモデル化: $r_i$ の事前分布の設計

平均ゼロで標準偏差  $\sigma$  の正規分布


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



個体差  $\{r_1, r_2, \dots, r_{100}\}$  がこの確率分布に従うとする

# $r_i$ の事前分布は無情報事前分布ではない


データにあわせて  $\sigma$  が変化する階層的な事前分布



- $\sigma$  がとても小さければ個体差  $r_i$  はどれもゼロちかくなる → 「どの個体もおたがい似ている」
- $\sigma$  がとても大きければ,  $r_i$  は各個体の生存数  $y_i$  にあわせるような値をとる

# 個体差 $r_i$ の事前分布は階層的な事前分布


(A) 主観的な事前分布 (B) 無情報事前分布 (C) 階層的な事前分布



- (A) 主観的な事前分布: 「自分の信じるところによれば,  $r_i$  たちはこんな分布になる」を表現している.
- (B) 無情報事前分布: 「 $r_i$  たちがどんな値になるのかまったくわかりません」を表現しようとしている (しかし -5 から 5 ぐらい, という主観も表現している).
- (C) **階層的な事前分布**:  $r_i$  の事前分布のパラメーター  $\sigma$  がいろいろな値をとる, そして  $\sigma$  についての超事前分布を設定する.

# パラメーターごとに事前分布を選ぶ (1)

(A) 主観的な事前分布 (B) 無情報事前分布 (C) 階層的な事前分布




(何か植物たちの統計モデリングをやっているとすると)

- fixed effects 的な効果:

- 無情報事前分布を設定する
- (実験処理の効果, 植物個体の大きさなど属性の効果などを) 全個体に共通する効果をひとつのパラメーターで表現しているから

# パラメーターごとに事前分布を選ぶ (2)

(A) 主観的な事前分布 (B) 無情報事前分布 (C) 階層的な事前分布




(何か植物たちの統計モデリングをやっているとすると)

- random effects 的な効果:
  - 階層的な事前分布を設定する
  - 個体ごとに異なるばらつき  $r_i$  が何かあって, しかし集団全体で  $\{r_i\}$  が何かの (意味ありげな) 確率分布にしたがっていると考えるのが妥当そうだから




# 階層的な事前分布と $y_i = 2$ の個体の $r_i$

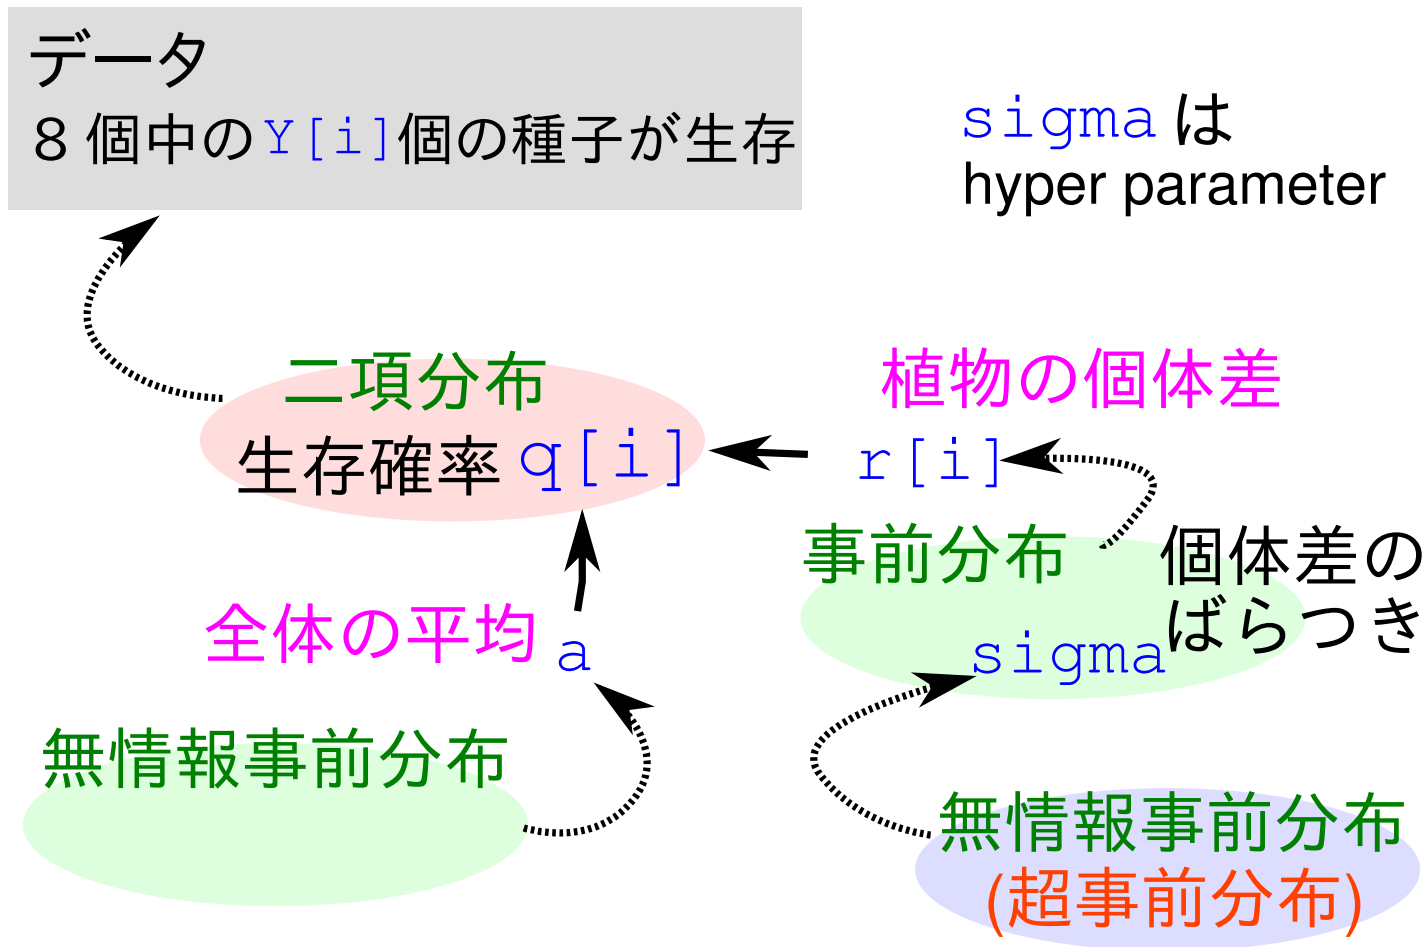


# 階層的な事前分布と $y_i \in \{2, 3, 5\}$ の個体の $r_i$

パラメーター  $\sigma$  が決める  
個体間の類似性



# なぜ「階層」ベイズモデルと呼ばれるのか？




超事前分布 → 事前分布という階層があるから

# 階層ベイズモデルではないベイズモデルって何でしょう？

個体差  $r_i$  の事前分布の設定を例に検討してみる

- 事前分布を主観的に決める  
「自分は  $\sigma = 0.1$  と信じるので、それを使う」
- 以前のデータを使う？  
「これまでの経験から  $\sigma = 0.1$ 」
- 無情報事前分布ばかりにする  
「よくわからないので  $\sigma$  をすごく大きくする」




(これらに対して)

観測データにもとづいて  $\sigma$  を決めようとする  
のが階層ベイズモデル

## 個体差 $\{r_i\}$ のばらつき $\sigma$ の無情報事前分布

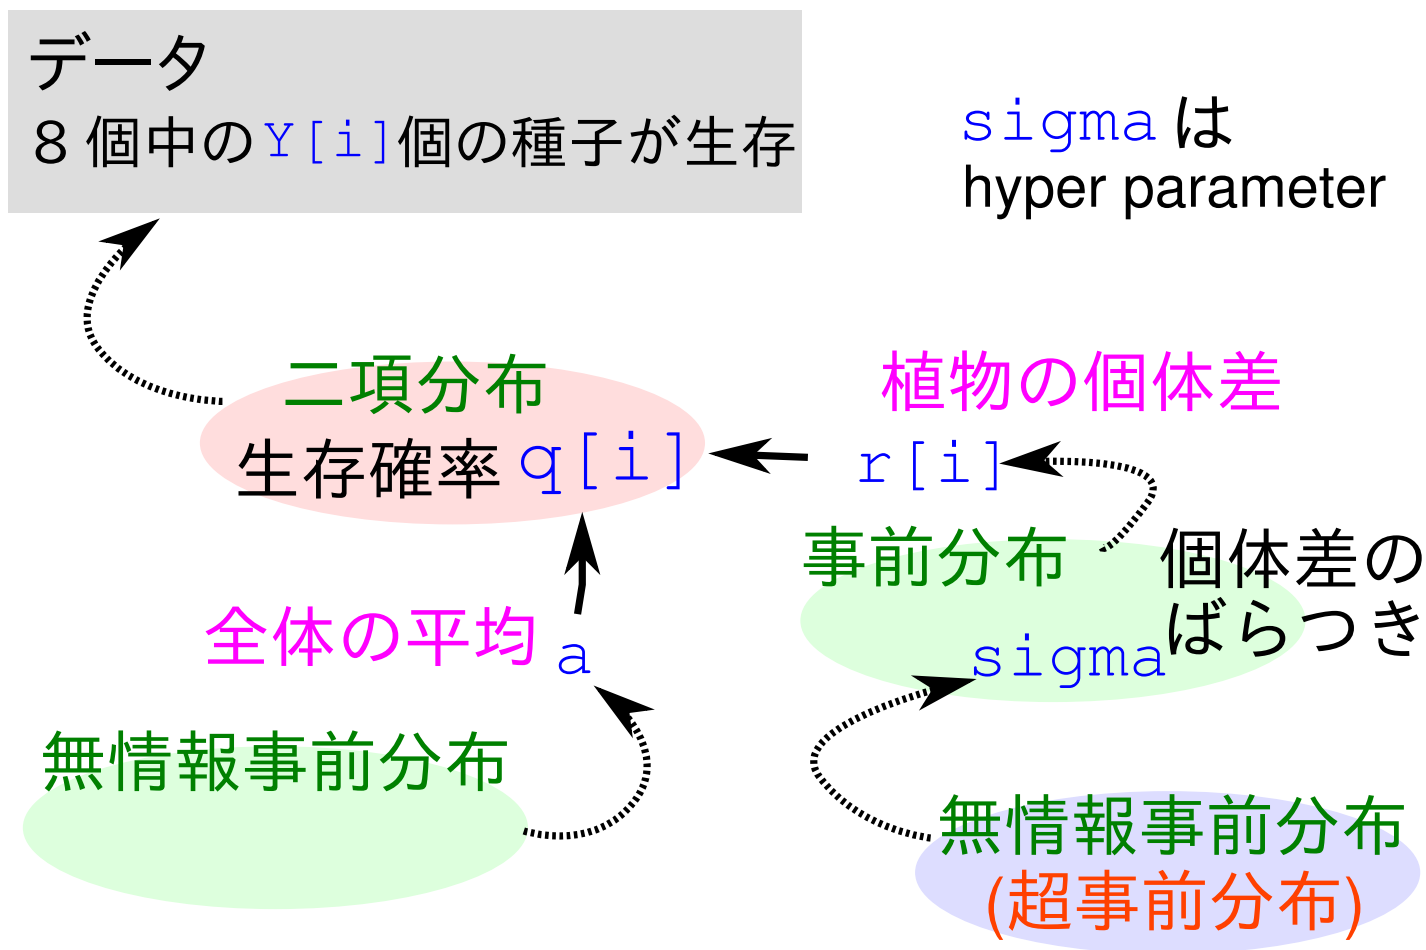
- $\sigma$  はどのような値をとってもかまわない
- そこで  $\sigma$  の事前分布は **無情報事前分布** (non-informative prior) とする
- たとえば一様分布
  - とりあえず, ここでは  $0 < \sigma < 10^4$  の一様分布としてみる

# 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

# 全パラメーターを一斉に推定する



矢印は手順ではなく，依存関係をあらわしている

どうやってパラメーター推定をするのか?


今回は省略 (次回に説明します)

WinBUGS + R でパラメーターの

事後分布が推定された, としましょう




# 推定された事後分布に基づく予測



「個体差」を考慮することで、  
少しはマシな統計モデルが作れた

# ここで使った解決策: さまざまな二項分布をませる

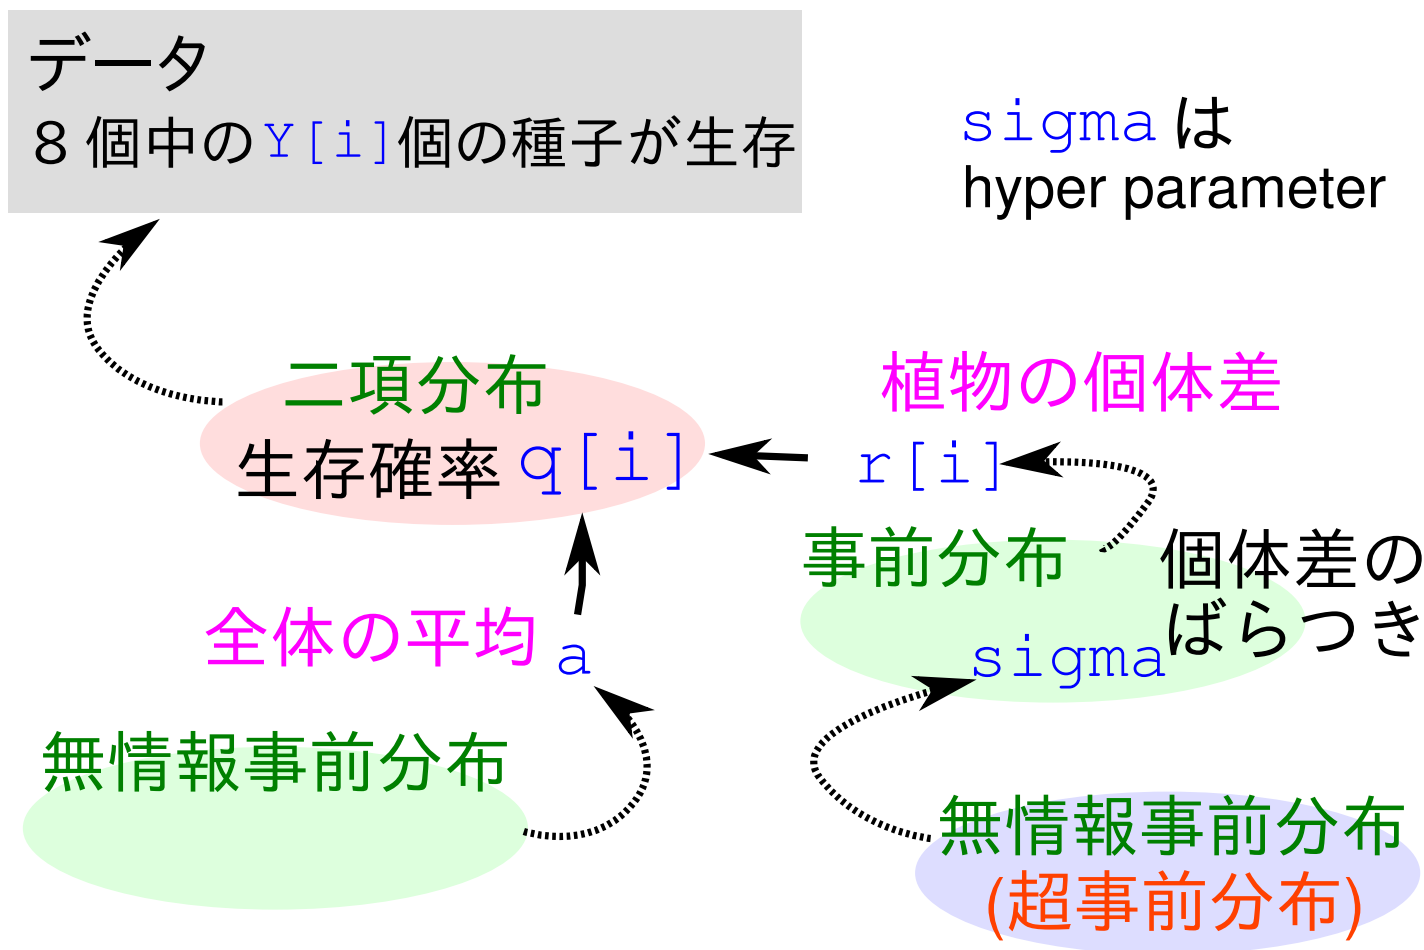


複雑な確率分布を新しく導入するのではなく  
二項分布と正規分布をませることで現象を表現した

# ここまでの用語の整理

- 階層ベイズモデル

$$(\text{事後分布}) \propto (\text{尤度}) \times (\text{事前分布}) \times (\text{超事前分布})$$

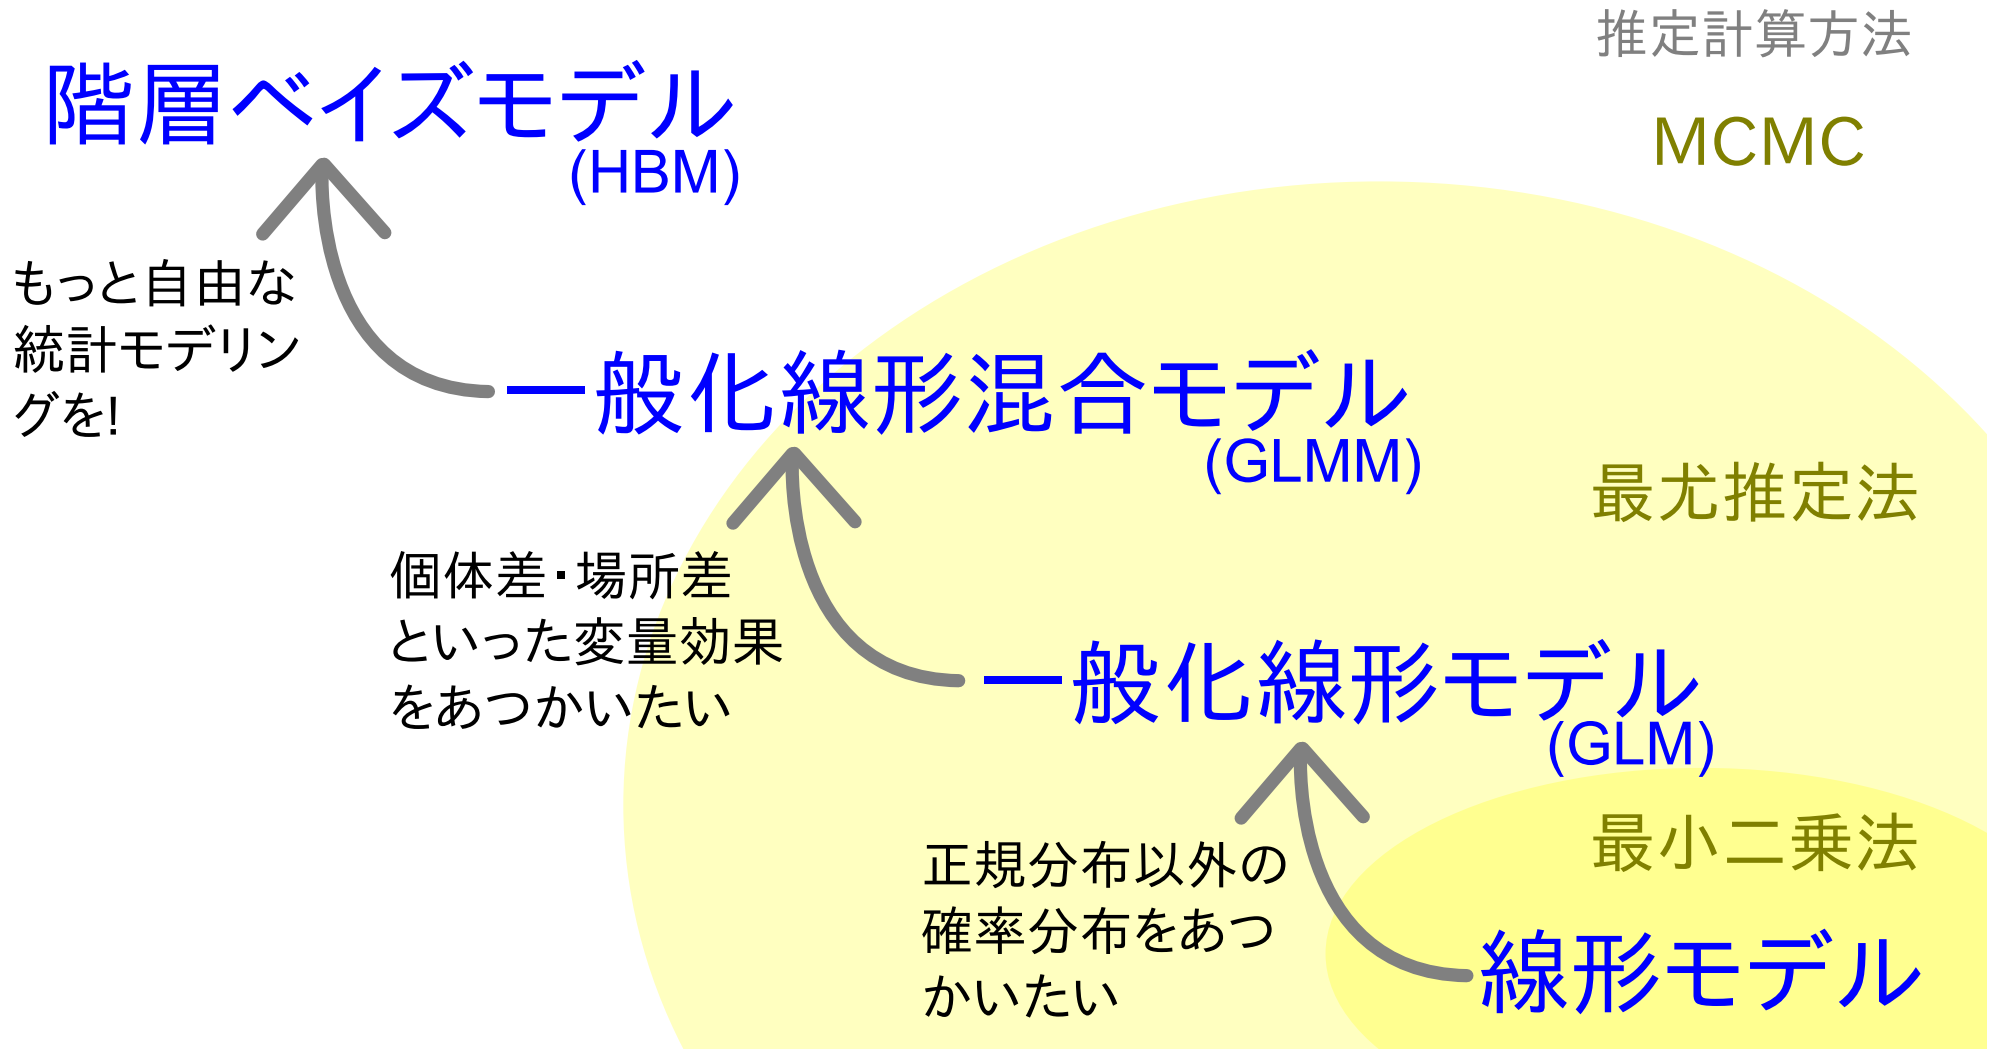


# 今日のハナシ

階層ベイズモデルでないとうまく表現できない現象がある

- 統計モデルは**尤度**であてはまりの良さを調べられる
  - 一番あてはまりが良いところをさがすのが**最尤推定法**
  - 尤度に比例するパラメーターの確率分布を推定するのが **MCMC**
- 現実的なデータ解析では個体差など **random effects** を考慮する必要あり
  - 単純な GLM ではそういうばらつきを表現できない
  - 階層ベイズモデル!

# 線形モデルの発展



# 階層ベイズモデルのご利益とは?

階層ベイズモデルでないとうまく表現できない現象がある

- 複数の random effects (個体差・ブロック差・縦断的データ・.....)
- 「隠れた」状態をあつかうモデル
  - 例: 「欠側値を補う」処理
- **空間構造**ある問題も MCMC 計算で
  - 例: 「隣は似てるよ」効果 – Gaussian Random Field

第6回・第7回でそういう例をいくつか紹介します