

# 入門 統計学 第15章

## ベイズ統計学

『入門 統計学 第2版 一検定から多変量解析・実験計画法・ベイズ統計学まで』 (オーム社)

※注：本書を購入された方へのサービスですので、教科書指定（参考図書は不可）していない授業での使用はお控えください。



# ベイズ統計学を使うべき人

帰無仮説が正しく無いことを反証(背理法)?



従来の統計学の考え方がしっくりこないわ...

小標本しか手に入らないわ...



類似の実験結果ならあるんだけど...

グループや場所の差をモデルに入れたいな



でも最尤法だと計算が不安定になりそう...

BIG DATA



新しいデータを次々と利用できるぞ!



# 15.1 ベイズ統計学とは

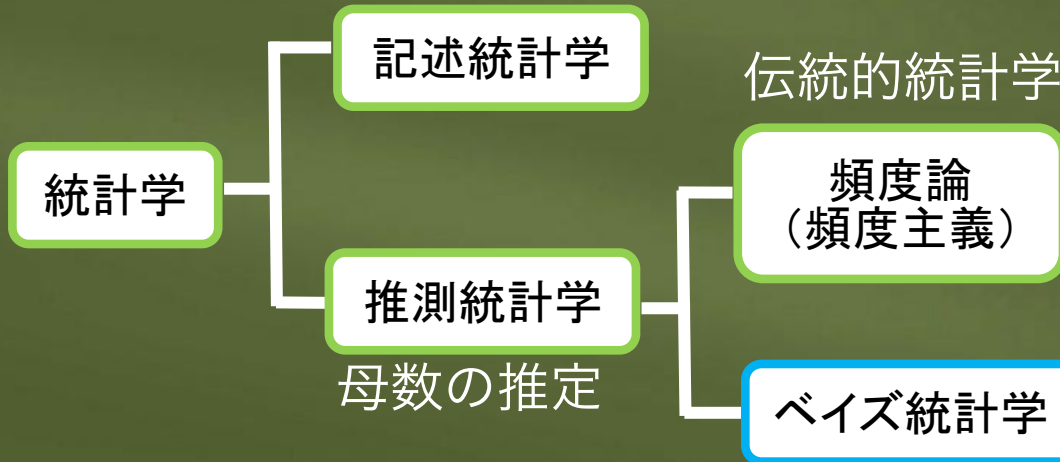
## ベイズの定理を土台とした推測統計学

(右が定理の生みの親であるトーマズ・ベイズ。ただし、体系的に確率的推論に本定理を<sup>データの整理</sup>使い出したのはラプラス)



T. Bayes  
(1702~1761)

(1705~1761)  
T. Bayes



考え方が異なるだけで、どちらが優れているわけではない

# ブームの到来！

## なぜ今、ベイズ統計学なのか？

理由①：情報分野の発達

→ビッグデータや機械学習との相性がよい

理由②：パソコン能力と計算アルゴリズムの飛躍的な向上

理由③：→課題であった複雑な積分が可能になった使いやすい無料ソフト (Stan) が現れ、メジャーなソフト (SPSS, STATA) にも実装

→いよいよ実践での利用が始まった



# ベイズ統計学の特徴

## 伝統的統計学との違い


- ❁ 特徴①：パラメータ自体の分布を推定できる
- ❁ 特徴②：事前情報や新しいデータを柔軟に取り込んで分析の正確さを向上できる
- ❁ 特徴③：複雑な統計モデルを推定できる

それぞれ簡単に解説しておきましょう...

# 特徴①：パラメータ自体の分布を推定できる (母平均の区間推定の例)


## 頻度論(第4章)

確率密度



## ベイズ統計学

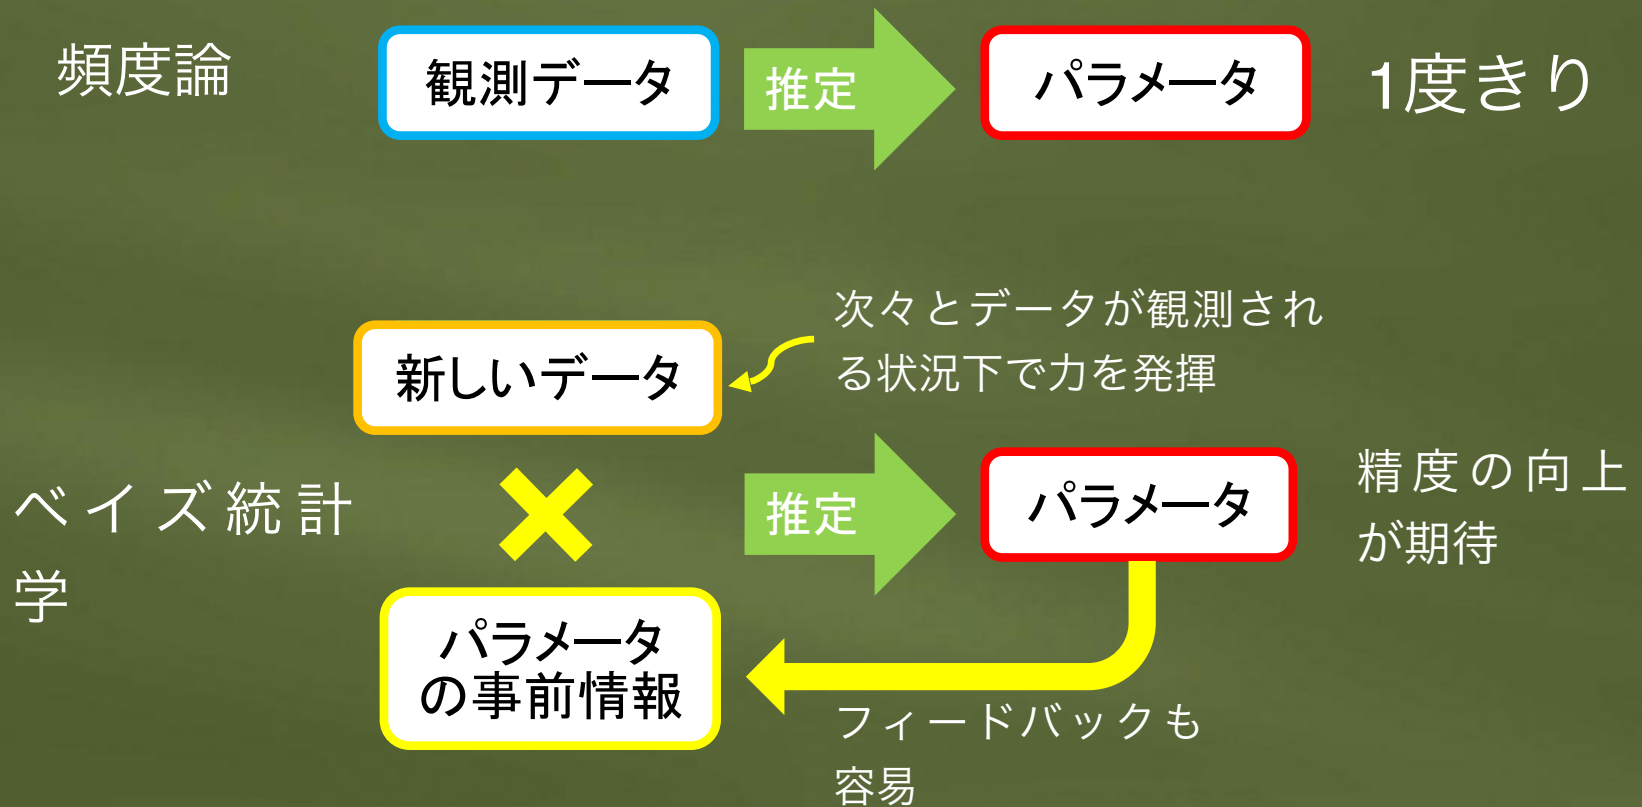
確率密度



確率変数の対象が異なる



# 特徴②：事前情報や新しいデータを柔軟に取り込んで精度向上



# 特徴③：複雑な統計モデルを扱える (一般化線形混合モデル)

固定効果

塾通ダ  
ミー

全体

固定効果

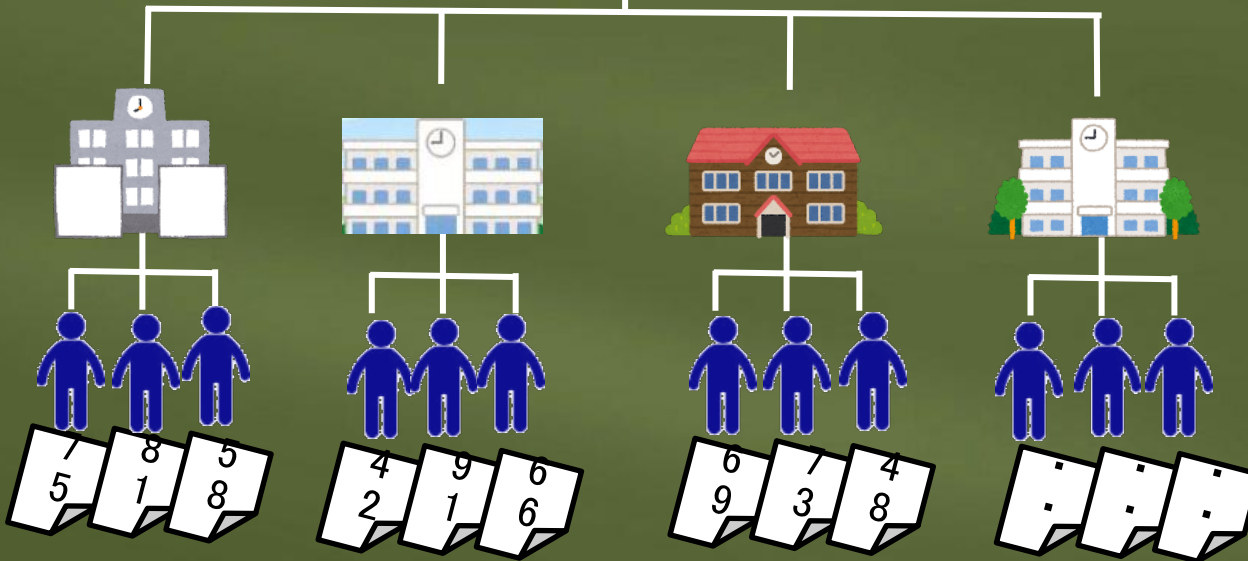
勉強時間

固定効果に併せて  
地域差などを**変量  
効果**として扱える

変量効果

学校差

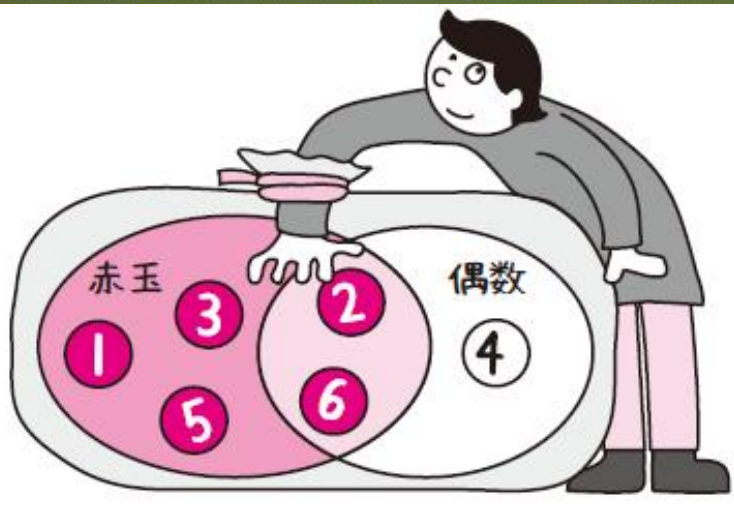
複雑な統計モデル  
を推定するのが最  
尤法よりも得意





# ベイズの定理は確率に関する式なので...

## まずは確率の計算（表現法）を復習



赤玉5個と白玉1個に①～⑥の番号を振って袋に入れた状態で、赤玉が出る事象をY、偶数が出る事象をXとします。

赤玉が出る確率  $P(Y) = \frac{5}{6}$

偶数玉が出る確率  $P(X) = \frac{3}{6}$

偶数の赤玉が出る同時確率  $P(Y \cap X) = \frac{2}{6}$

同時を表す記号(キャップ)

赤玉であるときに偶数である条件付き確率  $P(X|Y) = \frac{P(X \cap Y)}{P(Y)} = \frac{2}{5}$

条件を表す記号(ギブン) 条件

# 15.2 ベイズの定理

逆の条件付き確率で求める

ベイズの定理  $P(X|Y) = \frac{P(Y|X)P(X)}{P(Y)}$

定理を導き出しておきましょう…

条件付き確率①  $P(X|Y) = \frac{P(X \cap Y)}{P(Y)}$   
(先掲の式)

条件付き確率②  $P(Y|X) = \frac{P(X \cap Y)}{P(X)} \rightarrow P(X \cap Y) = P(Y|X)P(X)$   
(XとYが逆)

代入すればベイズの定理



# 結果から原因の確率を知る

Yを結果事象(事後), Xを原因事象(事前)と考えると…

ベイズの定理

$$P(X=x | Y=y) = \frac{P(Y=y | X=x) \cdot P(X=x)}{P(Y=y)}$$

↑

結果Yとしてyが観測されたとき, その原因Xがxである確率を求めることができる

↑ 時間の流れと逆の確率を, 時間の流れ順の確率などから求めることができる点が優れている



# 定理を構成する確率

すでにYはyであると確定しているので、Yが起こる“確率”は不自然

観測した結果Y(データ)から見て、それを生み出した原因がXである事の“尤もらしさ”

原因Xが起こる確率(=結果が観測される前の確率)

$$\text{事後確率}P(\text{原因}X|\text{結果}Y) = \frac{\text{尤度}P(\text{結果}Y|\text{原因}X) \times \text{事前確率}P(\text{原因}X)}{\text{全確率}P(\text{結果}Y)}$$

(逆確率とも)

結果Yとしてyが観測される確率：  
原因Xがxの場合とxでない場合の2つある場合、尤度の部分の $P(Y|X=x)P(X=x)$ と $P(Y|X \neq x)P(X \neq x)$ を足し合わせる(周辺化)と原因Xは消えて、結果Yだけの確率となるため、周辺尤度とも呼ぶ(後掲のサイコロのベン図を参照)



# ベイズの定理を使った例題

新型コロナウイルスのPCR検査を市中でランダムに実施した場合、陽性の反応が出た人が本当に感染している確率はどれぐらいでしょうか？ただし、市中感染率は0.1%で、偽陰性は30%、偽陽性は1%であると仮定します。

感染していることは原因（時間的に前）、陽性反応が出ることは結果（時間的に後）ですので、陽性反応が出た人が感染している確率は、時間の流れと逆の事後確率（逆確率）です。←ベイズの出

番

$$P(\text{感染} | \text{陽性}) = \frac{P(\text{陽性} | \text{感染})P(\text{感染})}{P(\text{陽性})}$$



# 例題の解答

		結果Y	
		陽性	陰性
原因X	感染 (0.1%)	70%	30% ← 偽陰性
	非感染 (99.9%)	1% ← 偽陽性	99%

$$P(\text{感染} | \text{陽性}) = \frac{P(\text{陽性} | \text{感染})P(\text{感染})}{P(\text{陽性} | \text{感染})P(\text{感染}) + P(\text{陽性} | \text{非感染})P(\text{非感染})}$$

$$= \frac{0.7 \times 0.001}{0.7 \times 0.001 + 0.01 \times 0.999} = 0.01069$$

陽性が出てても本当に感染している確率は意外と低い



個々の事象についての確率から分布に一般化

## 離散型確率分布の場合

原因Xを**パラメータ** $\Theta$ <sup>シータ</sup> (実現値は $\theta_i$ ), 観測データをY (実現値はy) と考えると...

結果である観測データを  
生み出した原因こそが統  
計モデルのパラメータ

飛び飛びの値  
が複数あるの  
でiを付ける

結果は2値の場合なども  
あるのでは付けない

全 $\theta_i$ のPをまとめれば  
事前分布(パラメータの分布)

離散型分布の  
ベイズの定理

$$P(\Theta = \theta_i | Y = y) = \frac{\overset{\text{尤度}}{P(Y = y | \Theta = \theta_i)} P(\Theta = \theta_i)}{P(Y = y)}$$

全 $\theta_i$ のPをまとめ  
れば事後分布

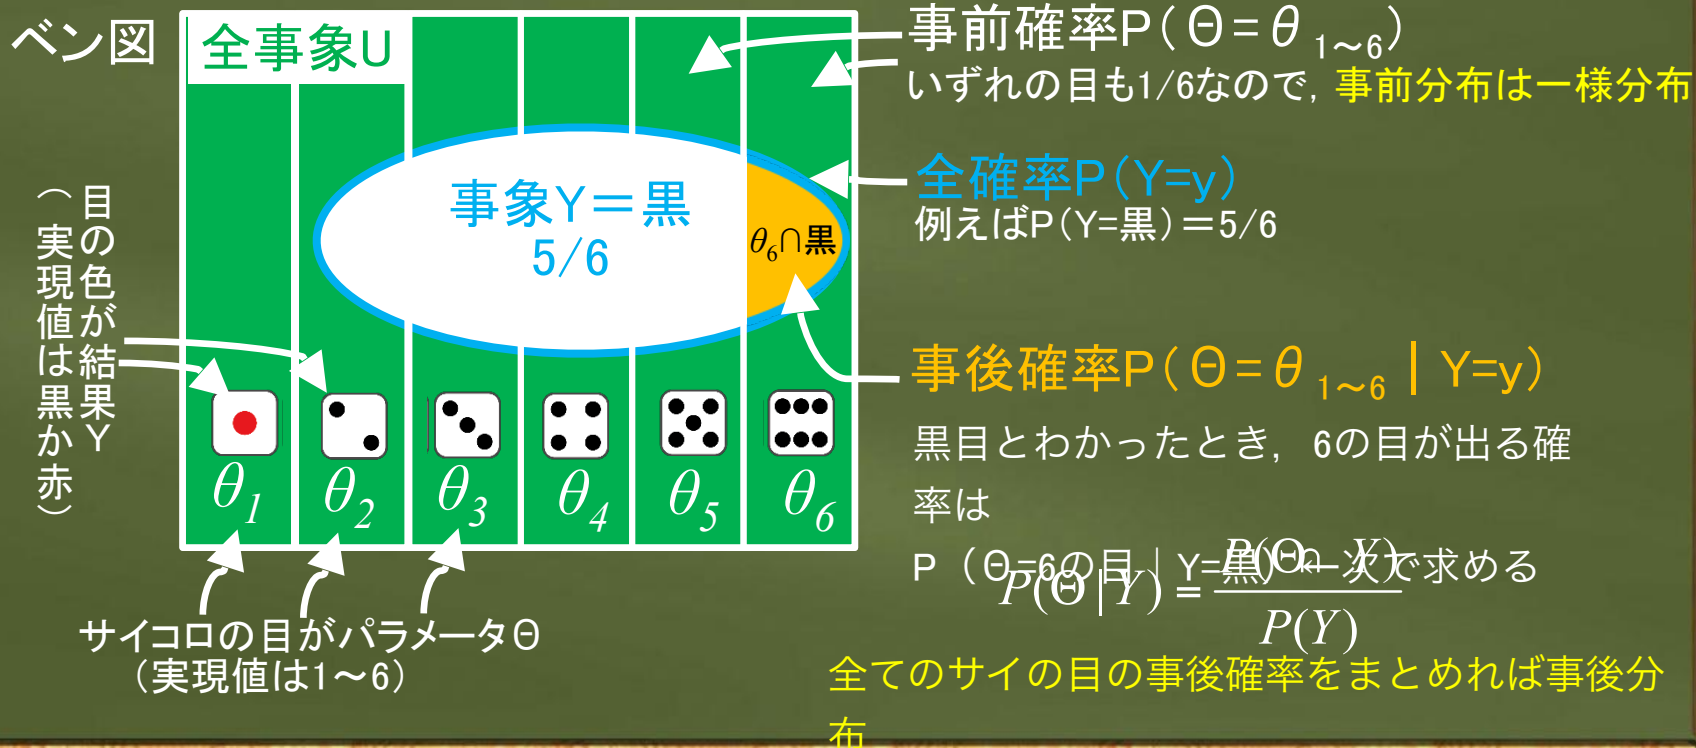
全確率(周辺尤度)

$$\sum P(Y | \Theta = \theta_i) P(\Theta = \theta_i)$$

# 離散型分布にベイズの定理を用いた事例①

## (1個のサイコロ振りにおける事後分布)

サイコロの目を原因(パラメータ), 目の色(黒/赤)を結果(データ)と考える





# 離散型分布にベイズの定理を用いた事例②

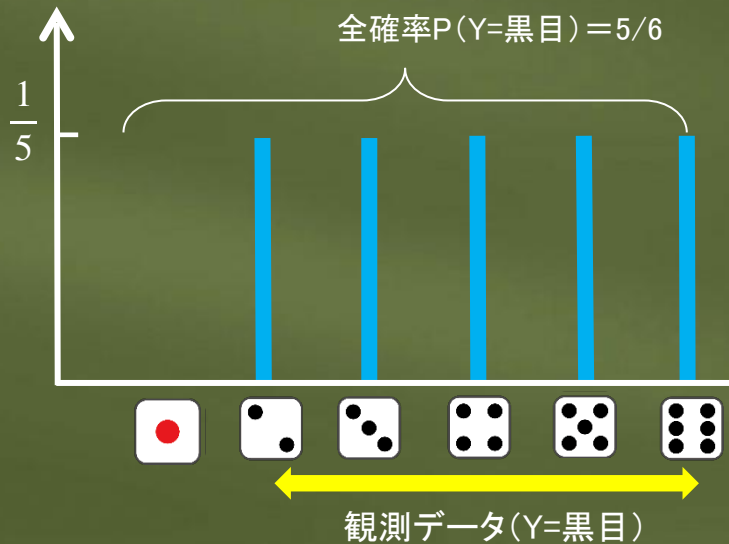
## (1個のサイコロ振りにおける事後分布)

黒い目が観測されたとき、6の目(パラメータ)である事後確率

$P_6$

$$\left( \frac{P_{\text{黒}}}{P_{\text{黒}}} \right) \left( \frac{1}{6} \right)^{-1} = \frac{1}{\left( \frac{0}{6} + \frac{1}{6} + \frac{1}{6} + \frac{1}{6} + \frac{1}{6} + \frac{1}{6} \right)} \times \frac{1}{6}$$

事後確率  
 $P(\theta = \theta_{1 \sim 6} | Y = \text{黒目})$



全てのPをまとめて考える

データとして黒い目 (Y=黒) が観測されたときの事後分布


パラメータ  $\theta_{1 \sim 6}$   
(確率変数=目)

# 離散型分布にベイズの定理を用いた事例③

## 事後分布の評価 (パラメータの推定)

データから獲得 → **パラメータの分布(事後分布)が得られれば色々な方法でパラメータを評価できる**

事後確率  
 $P(\theta = \theta_{1 \sim 6} | Y = \text{黒目})$



事後中央値MED (事後分布全体の確率が半分になる点) = 4

事後期待値(平均値)EAP (第2章)

$$E(\theta) = \sum_{i=1}^6 \theta_i \cdot \frac{1}{5} = \frac{1}{5} + \frac{2}{5} + \frac{3}{5} + \frac{4}{5} + \frac{5}{5} + \frac{6}{5} = \frac{21}{5} = 4.2$$

事後分散(第2章)

$$V(\theta) = \sum_{i=1}^6 \theta_i^2 \cdot \frac{1}{5} - (E(\theta))^2 = \frac{1}{5} + \frac{4}{5} + \frac{9}{5} + \frac{16}{5} + \frac{25}{5} + \frac{36}{5} - (4.2)^2 = \frac{91}{5} - 17.64 = 1.16$$
$$+ (3 - 4)^2 \times \frac{1}{5} + (4 - 4)^2 \times \frac{1}{5} + (5 - 4)^2 \times \frac{1}{5} + (6 - 4)^2 \times \frac{1}{5} = \frac{1}{5} + 0 + \frac{1}{5} + \frac{4}{5} = \frac{6}{5} = 1.2$$

黒が観測されたとき, 60%の確率で真のサイコロの目が含まれる**信用区間**[3, 5]

事後確率最大値MAP: 事後確率が最も大きな  $\theta$  が推定値 (今回は2~6が同じ事後確率なので適さない)



# 連続型確率分布のベイズの定理

現実の世界では重さや長さなど、変数(パラメータ)は連続している…  
(注: 確率Pの代わりに確率密度関数fを導入)

連続型分布の  
ベイズの定理

$$f(\theta | y) = \frac{f(y | \theta) f(\theta)}{\int_{-\infty}^{\infty} f(y | \theta) f(\theta) d\theta}$$

事後分布  
尤度 事前分布  
確率密度関数  
周辺尤度

$\int_{-\infty}^{\infty} f(y | \theta) f(\theta) d\theta$   
周辺化によって $\theta$ と関係なくなり、確定している $y$ だけで決まる(つまり定数)  
事後分布の面積を1にする役割があるため正規化(規格化)定数とも呼ぶ

簡略表現

プロポーション  
比例

ベイズ統計学  
の基本式

$$f(\theta | y) \propto f(y | \theta) f(\theta) \rightarrow \text{事後分布} \propto \text{尤度} \times \text{事前分布}$$


# 連続型事後分布によるパラメータ評価①

## (区間推定)

(離散型同様)事後分布からパラメータの推定量  $\hat{\theta}$  を求められる

パラメータを95%の確率で含む信用(確信)区間は、下記の上下限界値で挟まれた範囲:

事後確率密度  
 $f(\theta | y)$



$$\text{上限値 } F(\hat{\theta}_{upper} | y) = \int_{\hat{\theta}_{upper}}^{\infty} f(\theta | y) d\theta = 0.025$$


$$\text{下限値 } F(\hat{\theta}_{lower} | y) = \int_{-\infty}^{\hat{\theta}_{lower}} f(\theta | y) d\theta = 0.025$$

下から積分して0.025となる値が下限値



# 連続型事後分布によるパラメータ評価②

## (3種類の点推定)



事後期待値 (EAP)

事後確率最大値 (MAP)

事後中央値 (MED)

$$\hat{\theta}_{eap} = E(\Theta) = \int_{-\infty}^{\infty} \theta f(\theta | y) d\theta$$


$$\hat{\theta}_{map} = \max_{\theta} f(\theta | y)$$

$$F(\hat{\theta}_{med} | y) = \int_{-\infty}^{\hat{\theta}_{med}} f(\theta | y) d\theta = 0.5$$

左右対称の事後分布ならば全て同じ推定値となる

# 連続型事後分布によるパラメータ評価③

## (事後分散)

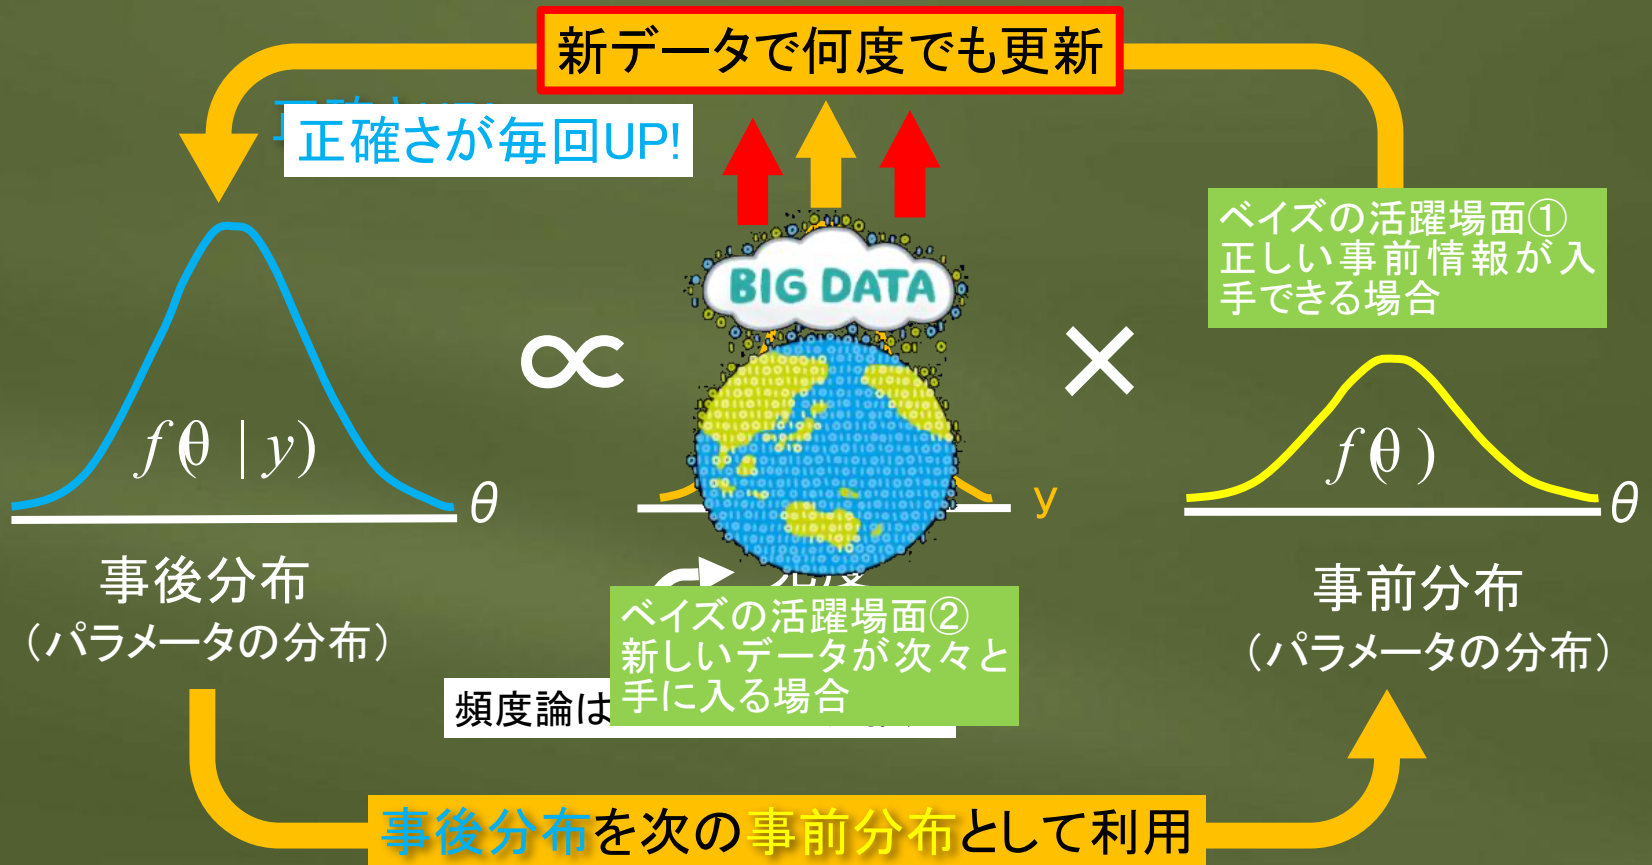


事後分散  $V(\Theta) = \int_{-\infty}^{\infty} (\theta - E(\Theta))^2 f(\theta | y) d\theta$



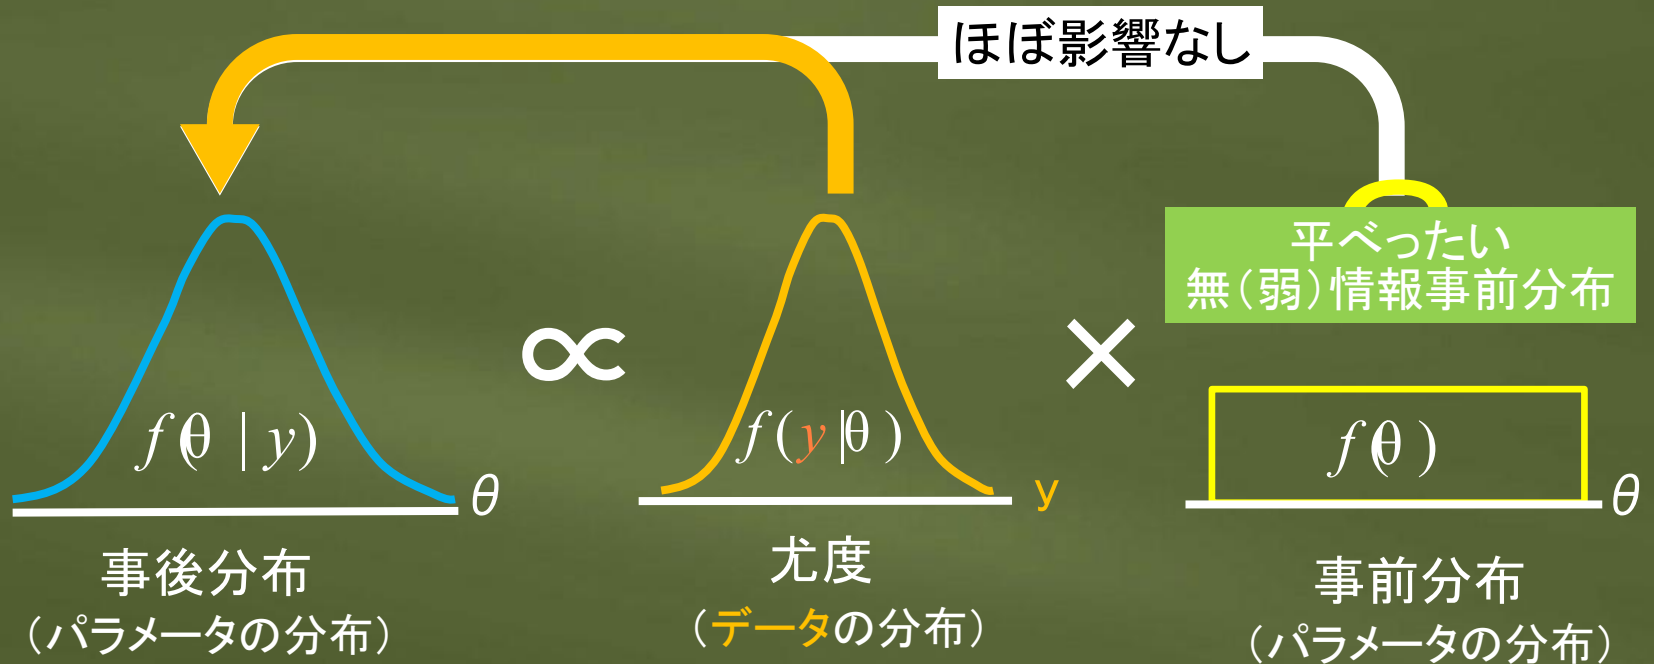
# 15.3 活躍場面 その1

## ベイズ更新



# パラメータに関する事前情報がなかったら？

事前情報を利用できなくても、パラメータの分布が得られるというベイズ統計学の利点は生かせる





# 回帰モデルのベイズ推定①

## (線形単回帰の事後分布)

単回帰モデル  $y = \alpha + \beta x + u$   $u \sim N(0, \sigma^2)$

$y$ は平均 $\alpha + \beta x$ ,  
分散 $\sigma^2$ の正規分  
布に従っている

$y \sim N(\mu, \sigma^2)$   $\mu = \alpha + \beta x$

$y$ が従う分布に注目して表現し直すと...

データ( $y$ と $x$ )は,  $\alpha$ と $\beta$ と $\sigma^2$ をパラメータとした  
統計モデルから生成(次掲図参照)

事後分布                      尤度                      事前分布

単回帰モデルのパラ  
メータの事後分布  $f(\alpha, \beta, \sigma^2 | y, x) \propto f(y, x | \alpha, \beta, \sigma^2) \times f(\alpha) \times f(\beta) \times f(\sigma^2)$

多変量の分布だが, 周辺化してい  
けば単純になる(例えば $\sigma$ で積分  
すれば $\alpha$ と $\beta$ の事後分布になる)

$-\infty \sim \infty$ なので $\sigma=100$   
の正規分布など

$0 \sim \infty$ なので正値  
の一様分布など

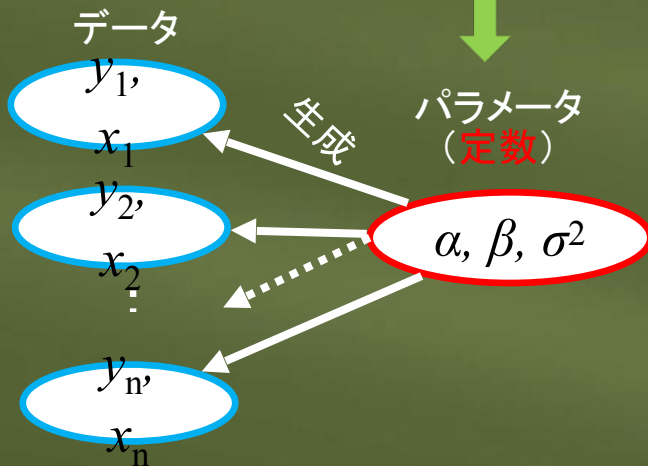
# 回帰モデルのベイズ推定②

(頻度論との比較)

頻度論

点推定

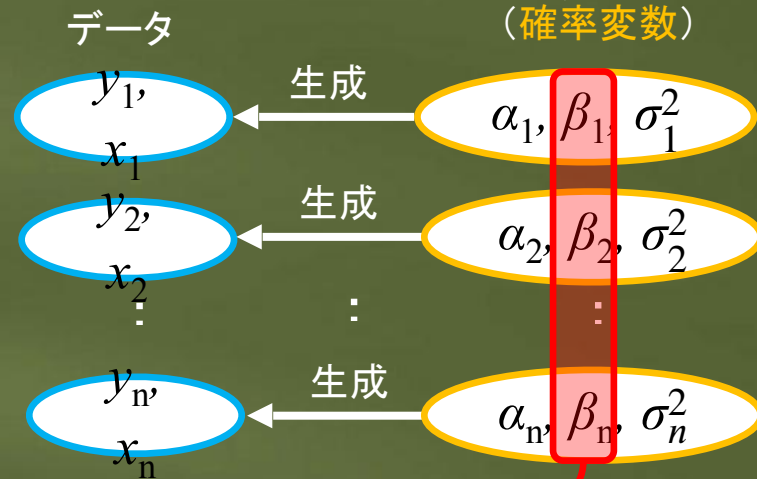
yとxを固定してパラメータを推定する



ベイズ

分布を推定

パラメータ  
(確率変数)



回帰係数  $\beta$  の分布



# 15.4 活躍場面 その2

## 入れ子構造のデータ（線形単回帰の例）

学校j	生徒i	成績yi	学習時間xi
1	1	75	4
1	2	81	6
1	3	58	1
2	4	42	0
2	5	91	5
2	6	66	3
3	7	69	2
3	8	73	2
3	9	48	0
...	...	...	...

これまでは**固定効果**※のみのモデルを考えてきた…

固定効果のみ

$$y_i = \alpha + \beta x_i + u_i \quad u_i \sim N(0, \sigma^2)$$

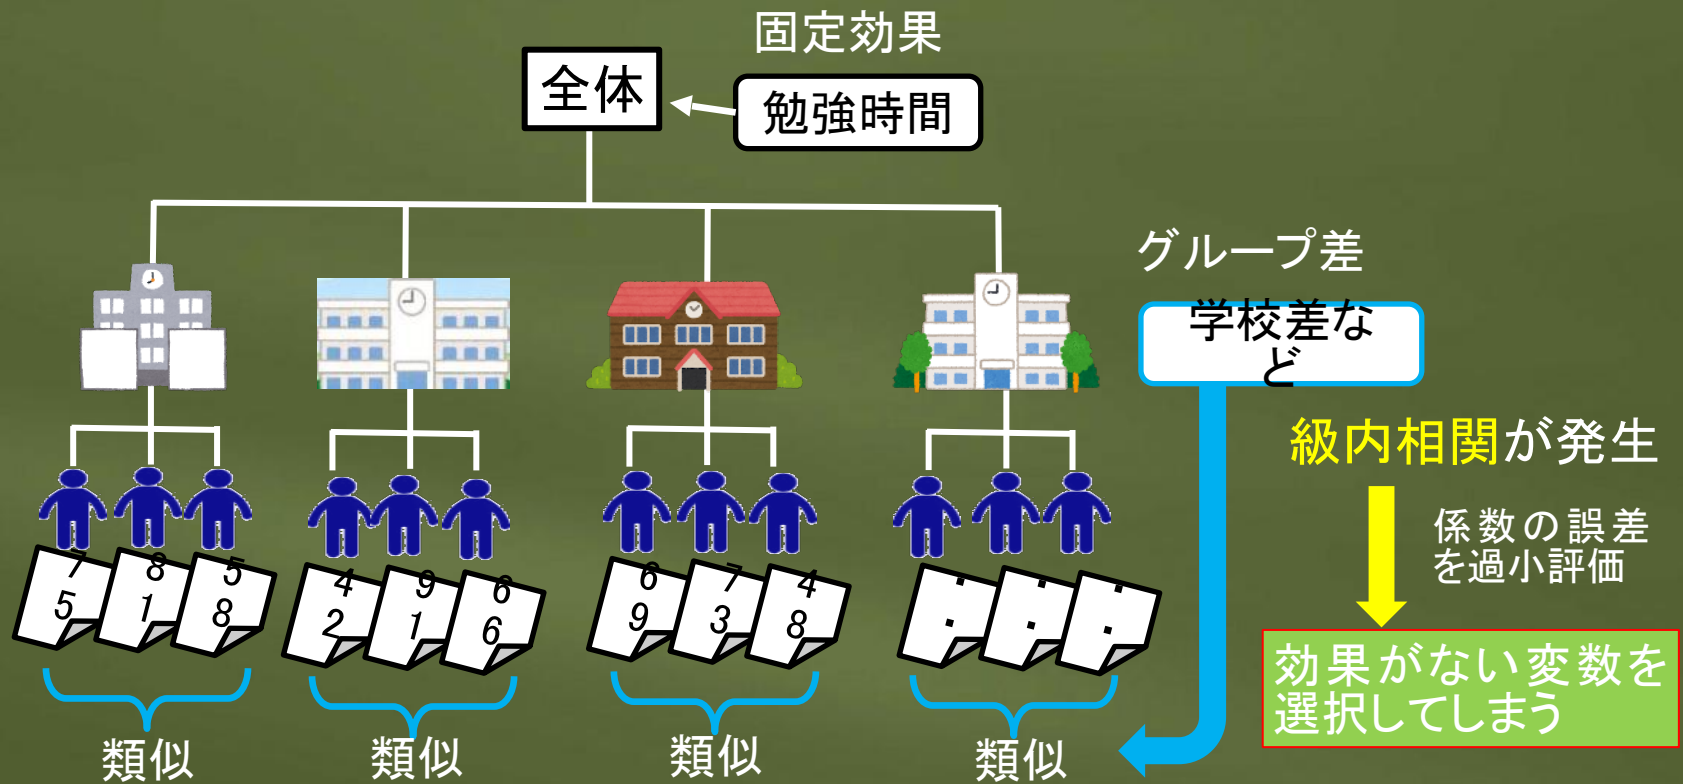
未知のパラメータは3つ

※**固定効果**(fixed effect)：変数の1つ1つの特定の水準が結果に与える影響（定数項  $\alpha$  も固定効果に含まれる）

学校差などグループ差がある場合、モデルに取り込まないと、どうなる？

グループ差 ? 結果 固定効果

# 入れ子構造のデータの課題





# グループ差の処理法

❖ グループごとに別々のモデルを推定

→モデルごとの標本サイズが小さくなる

❖ グループごとにダミー変数を作成して、固定効果として1つのモデルを推定

→グループ数が多いと煩雑になり、階層間で多重共線性が発生する可能性

❖ **変量効果** (random effect)として1つのモデルに取り込み推定

→**混合モデル** (この後解説)

# 固定効果と混合効果の 混合（効果）モデル

$j$ はグループ、黄色は推定すべきパラメータ

$$y_{ij} = \alpha_j + \beta_j x_{ij} + u_{ij}$$

定数項

係数

$$\beta_j = \mu_\beta + r_{\beta j}$$

$$\alpha_j = \mu_\alpha + r_{\alpha j}$$

固定効果 変数効果

グループ差によるバラツキ  
の効果(確率分布に従う)

$$u_{ij} \sim N(0, \sigma_y^2)$$

$$r_{\beta j} \sim N(0, \sigma_\beta^2)$$

$$r_{\alpha j} \sim N(0, \sigma_\alpha^2)$$

正規分布

平均0, 分散 $\sigma^2$ の正規  
分布とする場合が多い

注: 混合モデルは本来, 計画行列を使って表記しますが, 難しいので, 本書では『StanとRでベイズ統計モデリング(松浦)』や『基礎から学ぶマルチレベルモデル (Ita Krefl)』の表記法を採用しています。



# 複雑な混合モデルに最尤法は適さない

混合モデルに最尤法を用いた場合の問題点：

①各グループが平均よりも正や負にどのくらい大きいのか ( $r_j$ の個別値) は計算できない(知りたくない場合はOK)

→変量効果の分散  $\sigma^2$  を積分で求めるときに周辺化されて消えるため  
混合効果    固定効果    変量効果

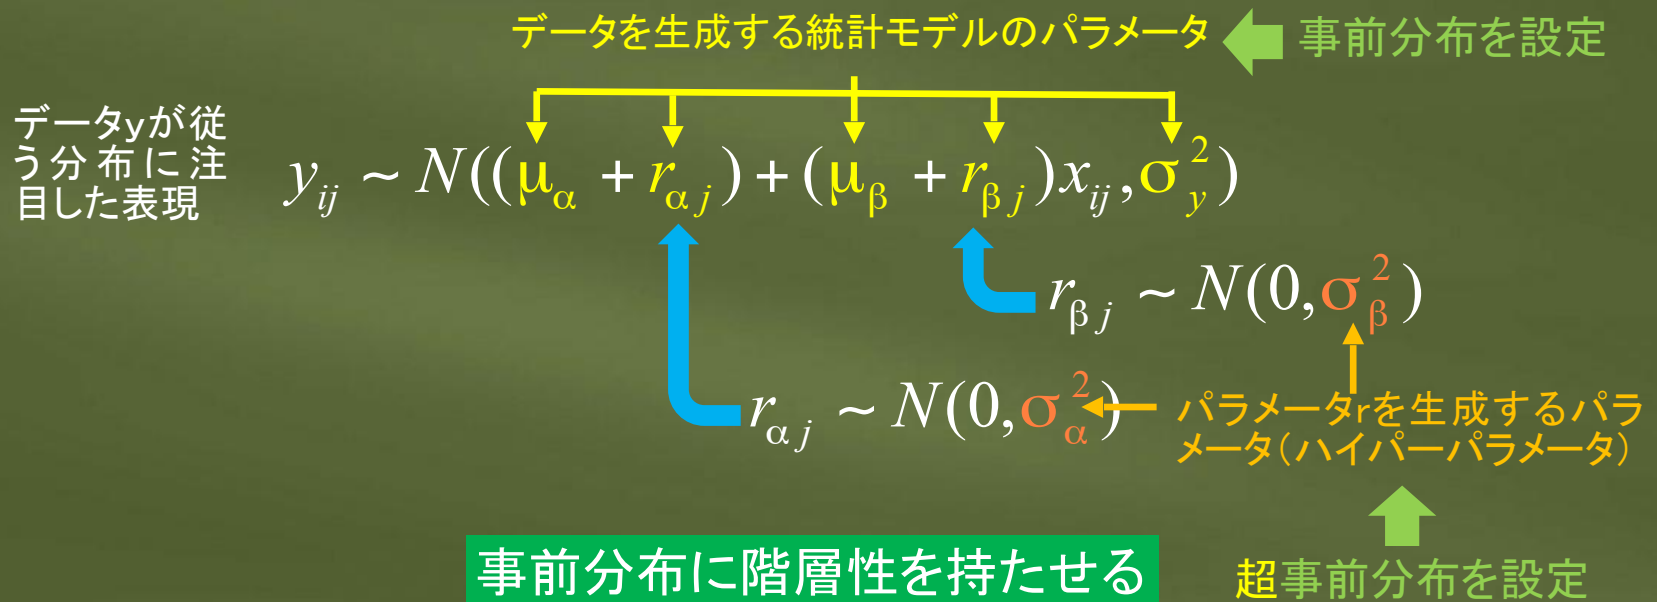
$$\beta_j = \mu_\beta + r_{\beta j}$$

グループjの全体平均  $\mu_\beta$  からのズレなので、パラメータはj個ある

②そもそも最尤法はパラメータの多い複雑なモデルには適さない  
→複雑なモデルでは漸近性(大標本ならば最尤推定量が正規分布に従う性質)が保証されないため、真の値から離れたり検出力が弱くなる  
→パラメータがそれぞれ異なる確率分布に従う場合に確率の積を計算するのは大変なので不安定になる

# 階層ベイズモデル①

ベイズならば、尤度に対して、データ構造に応じたパラメータの事前分布を次々と乗ずることで、幾多のパラメータをも混ぜこぜにした1つの事後分布として扱える(グループ別の変量効果も計算できるし、漸近性も不要)





# 階層ベイズモデル②

多次元の事後分布から、いずれかのパラメータを推定するには多重の積分計算  $\int \int \int \int$  が必要…どうする？

事後分布

尤度

$$f(\mu_\alpha, \mu_\beta, \sigma_y^2, r_{\alpha j}, r_{\beta j}, \sigma_\alpha^2, \sigma_\beta^2 | y_{ij}, x_{ij}) \propto f(y_{ij}, x_{ij} | \mu_\alpha, \mu_\beta, \sigma_y^2, r_{\alpha j}, r_{\beta j})$$

$$\times f(\mu_\alpha) \times f(\mu_\beta) \times f(\sigma_y^2) \times f(r_{\alpha j} | \sigma_\alpha^2) \times f(r_{\beta j} | \sigma_\beta^2) \times f(\sigma_\alpha^2) \times f(\sigma_\beta^2)$$

事前分布

パラメータ

ハイパーパラメータ

超事前分布

生成



事前分布が階層構造

(階層ベイズは、データが持つ階層構造の事ではない)

# 15.4 事後分布（によるパラメータ）の評価

## マルコフ連鎖モンテカルロ法（MCMC）

直接的な積分はあきらめて、事後分布から取ってきた乱数を使って推定

手順①: 事後分布から **マルコフ連鎖** を用いて **サンプリング** する

多変数の確率分布から **乱数** (パラメータと見なす) を取り出すこと

**MCMC**  
(数種類ある)

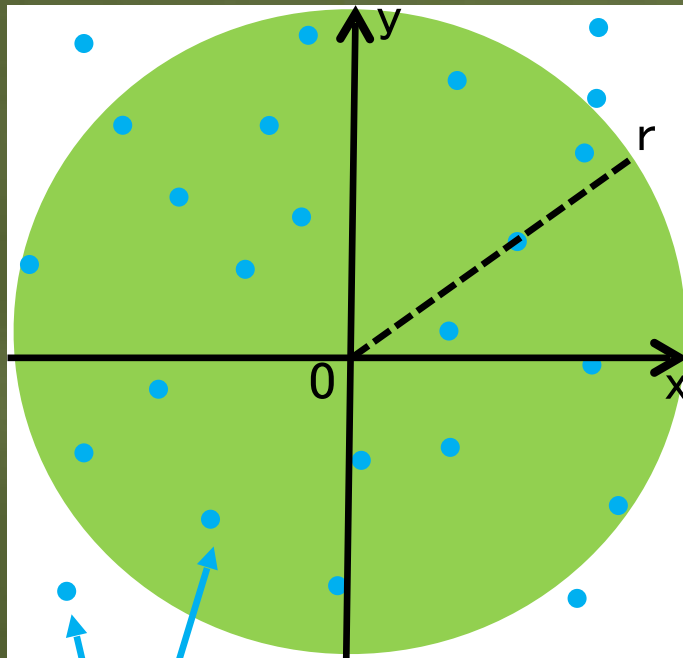
**モンテカルロ法**

手順②: サンプル(乱数の集合)に対して平均や分散を計算して **積分の代わり** とする



# モンテカルロ法 (積分の近似計算)

## 円の面積の計算例



ランダムに点(乱数)をばらまく

本来は  $\int_{-r}^r \sqrt{r^2 - x^2} dx \times 2$  とい

う積分計算が必要 ( $x^2 + y^2 = r^2$  よ

り) **円の中に入った個数  
÷ 全体の個数**

∴ 円の面積 = 外枠(四角形)の面積 × 確率  $p$

球の体積 (3次元) : 箱の中でランダムに点をばらまき, 球に入った数から求める

↑ パラメータが増えて次元が上がっても容易に対応

# マルコフ連鎖 (乱数の生成ルール)

高次元空間で完全にランダムに乱数を発生させるのは不効率

マルコフ連鎖で解決

未来の確率変数 (乱数)  $X_{n+1}$  が現在の値  $X_n$  だけから決定されるという考え方 (それより過去は無関係)

1期前の状態に依存

(マルコフ連鎖を規定する条件付き確率)

遷移核

$$P(X_{n+1} = x | X_n = x_n, \dots, X_1 = x_1) = P(X_{n+1} = x | X_n = x_n)$$

過去の値が全部わかっているという条件の下での未来の確率

現在の値だけがわかっているという条件の下での未来の確率

- メリット①: 1期前のみを参考にするため、効率よく乱数を取り出せる
- メリット②:  $p_1$  から  $p_2$ ,  $p_2$  から  $p_3$  ... と次々に求めていくと値は収束する (乱数を取ってくる事後分布が定常分布になる)



# マルコフ連鎖の事例

今日 $X_1$



鼻水は  
かなり出ていた

明日 $X_2$



鼻水の出る確率:  
今日出てたから...  
 $p_2=0.9$

あさって $X_3$



鼻水の出る確率:  
前日も少し出てたから...  
 $p_3=0.6$

100日後 $X_{101}$



鼻水の出る確率  
前日結構出てたから...  
 $p_{101}=0.8$

アレル  
ギー決定...

上がったり下がったりし  
ながら徐々に収束する

# 一番基本的なMCMC

## メトロポリス・ヘイスティングス法 (M-Hアルゴリズム)①

MCMC：遷移核を上手く設定して，事後分布が定常分布になるマルコフ連鎖を作り，そこから乱数を生成

→マルコフ連鎖の各要素 $X_{n+1}$ を，事後分布から取ってきた乱数（パラメータ） $\theta_{n+1}$ とみなす

次の乱数として提案された $\theta$

M-Hアルゴリズムの遷移核

$$r = \frac{\text{事}}{\text{事}}$$

$$\theta_{n+1} = \frac{f(y|\theta_{n+1})f(\theta_{n+1})}{f(y|\theta_n)f(\theta_n)}$$

1より大きければ $\theta_n$ よりも $\theta_{n+1}$ の方が確率密度が大きい（パラメータとして適している）

積分が面倒な正規化定数が消えるというメリット



# メトロポリス・ヘイスティングス法②

$$\text{確率密度} = \frac{\text{尤度} \times \text{事前分布}}{\text{正規化定数}}$$

確率密度の高いところで乱数が多くウロつく

たまに悪い方に移るようにすることで乱数をたくさん生成できる

$r < 1$ でも $r$ の確率で $\theta_{n+1}$ に移る  
( $1-r$ の確率で $\theta_n$ にとどまる)

$r \geq 1$ なら $\theta_{n+1}$ に移る


$$r = \frac{\text{確率密度} \theta_{n+1}}{\text{確率密度} \theta_n}$$

モンテカルロ法で信用区間などを求めることができる

乱数(パラメータ)

起きやすさに比例した密度の乱数

事後分布の実現値



## 15.5 まとめ

### ベイズの注意点とソフトウェア

❖ あまり複雑なモデル（多階層の入れ子構造など）を想定しない

→MCMCでパラメータの推定値が収束し難くなる

❖ 恣意的な事前分布を設定しない

→データ取得が1回きりで、客観性や公平性が重視される分野なら頻度論にしておく



(参考)

# SPSSによるベイズ統計学

## 独立した2群の平均の差の推定①

新しい販売促進がクレジットカード使用額に与えた影響分析 (サンプルファイル:

C:\Program Files\IBM\SPSS\27\Samples\Japanese



	id	配布	トータル
1	148	0	2232.77
2	572	1	1403.81
3	973	0	2327.09
4	1096	0	1280.03
5	1541	1	1513.56
6	1947	1	1729.63

何の事前情報もないので、  
とりあえず不等分散とする (分布形は正規分布とする)

(参考)

# SPSSによるベイズ統計学



## 独立した2群の平均の差の推定②




— 対数尤度関数  
— 事前分布  
— 事後分布

観測された2群のデータの分布 (対数尤度)

×



2群の事前分布 (今回は事前情報はないので一様分布)



平均: 販売促進期間に費やした金額(ドル)

母平均の差の確率分布

||



(参考)

# SPSSによるベイズ統計学

## 独立した2群の平均の差の推定③

	事後分布			95% 信用区間	
	最頻値	平均値	分散	下限	上限
販売促進期間に費やした金額(ドル)	71.1110	71.1110	997.691	9.1767	133.0452

a. 分散の事前確率: Diffuse。平均の事前確率: Diffuse。

真値（母平均の差）が95%の確率で含まれると信用できる区間

検定のようなこともできる（パラメータの分布が求まるので必要性は低い）↓

	平均値の差	プールされた差の標準誤差	ベイズ因子 <sup>b</sup>	t 値	自由度	有意確率 (両側)
販売促進期間に費やした金額(ドル)	71.1110	31.45914	1.150	2.260	498	.024

a. グループ間で不等分散を仮定します。  
b. ベイズ因子: 帰無仮説 対 対立仮説。

グループ2（新しい販売促進）の方がグループ1（標準）のモデルよりも尤もらしい。

(参考)

# STATAによるベイズ統計学

## 線形混合モデル①

表15.1の成績のデータ(線形混合モデル)

固定効果に学習時間,  
変量効果に学校を設定

学校別の変量効果  
の値を表示する

統計(S) ユーザ(U) ウィンドウ(W) ヘルプ(H)

- 要約/表/検定
- 線形モデル他
  - アウトカム(二値)
  - アウトカム(順序型)
  - アウトカム(カテゴリ)
  - アウトカム(カウント)
  - アウトカム(フラクショナル)
  - 一般化線形モデル
  - 選択モデル
- 時系列
- 多変量時系列分析
- 空間自己回帰モデル
- 縦断的/パネルデータ
- マルチレベル混合効果モデル**
  - 線形回帰
  - 非線形回帰
  - ロジスティック回帰
  - プロビット回帰
  - 補二重対数回帰
  - 順序ロジスティック回帰
  - 順序プロビット回帰
  - ポワソン回帰
  - 負の二項回帰
  - トービット回帰
  - 区間回帰
  - 一般化線形モデル(GLM)
  - パラメトリック生存回帰
  - QR分解を用いた推定
  - ベイジアン回帰**
- 生存分析
- 疫学関連
- 内生変数
- サンプルセレクションモデル
- 処置効果
- SEM(構造方程式モデリング)
- LCA(潜在クラス分析)
- FMM(有限混合モデル)
- IRT(項目応答理論)
- 多変量解析
- サーバイデータの分析
- Lasso
- メタ分析
- 多重代入法

モデル if/in 加重 事前分布 シミュレーション

固定効果モデル

従属変数: **成績** 独立変数: **学習時間**

定数項を利用しない

ランダム効果モデル

ランダム効果のコマンド式:

**式1**

|| 学校:

コマンド式のレベル(グループ変数): **学校**

コマンド式での独立変数  
 コマンド式での因子変数

出力レポートオプション

モデルのパラメータを表示する

- すべて表示する
- 選択した項目を表示する
- 選択した項目を表示しない

ランダム効果を表示する

- すべてのランダム効果を表示する
- 選択したランダム効果を表示する



(参考)

# STATAによるベイズ統計学

## 線形混合モデル②

```
Bayesian multilevel regression
Metropolis-Hastings and Gibbs sampling
Group variable: 学校
MCMC iterations = 12,500
Burn-in = 2,500
MCMC sample size = 10,000
Number of groups = 3
Obs per group:
  min = 3
  avg = 3.0
  max = 3
Number of obs = 9
Acceptance rate = .8121
Efficiency: min = .0318
              avg = .2317
              max = .6318
```

事後分布の評価

Log marginal-likelihood

	平均 Mean	標準偏差 Std. Dev.	標準誤差 MCSE	中央値 Median	信用区間 Equal-tailed [95% Cred. Interval]	
成績						
学習時間	6.812599	1.714658	.021572	6.828337	3.405889	10.23423
cons	49.85974	6.470371	.137288	49.771	36.81623	63.04366
u0[学校]						
1	-1.012968	3.438104	.192809	-.1212398	-11.00991	3.773118
2	-.5387752	3.044413	.144845	-.0163995	-8.70026	4.795246
3	.7505432	3.20943	.144893	.1334103	-4.996328	9.346132
学校						
u0:sigma2	31.59324	192.6665	4.77957	.9246839	.0073184	242.2062
e.成績						
sigma2	84.94981	76.05439	1.09737	62.85645	21.48052	283.0922

乱数の数

M-H法で提案した

$\theta_{n+1}$ が受容された比率  
(0.1以下は問題あり)

回帰係数

学校別の  
変数効果

学校差の大きさ  
(変数効果の分散)

成績(残差)の  
分散

以上で第15章は終了です。