

統計モデリング入門 2017 (j)

分割の統計モデル Categorical Data Analysis

久保拓弥 kubo@ees.hokudai.ac.jp

北大環境科学院の講義 <http://goo.gl/76c4i>

2017-11-15

ファイル更新時刻: 2017-11-08 17:11

ちょっと批判してみたい、よくみかける「お作法」

Spc	x	A	B	C	D	E	F	G	H	I
0	62	21	14	11	10	10	2	0	2	
1	48	34	22	17	16	7	2	1	1	

こういう表をみたときに反射的に……

- 表の検定 だからカイ二乗検定やればいいやー
 - 「なんでも検定」かよー
 - データ解析 ≠ 検定 !! 検定はデータ解析の一部 !!
- 「5以下のセル」があるから検定できーん
 - その根拠は何 ?!
- データを捨てれば検定できるー !!
 - 捨てるな !!

分割表である、どんなデータであれ

- まず「どんな統計モデルで説明できるか」を考える
- カウントデータの場合は、とりあえず GLM で説明できなか考へてみる
- 次の項目をきちんと区別しよう
 - データを発生させうる統計モデル
(例: GLM や階層ベイズモデル)
 - 統計モデルのパラメーター推定方法
(例: 最尤推定法や MCMC 法)
 - 推定結果の比較方法
(例: Neyman-Pearson な検定, モデル選択, 信用区間)

2 × 2 の分割表

粕谷さんの話に登場した内容もくりかえしつつ

今日の例題: 調査区画に出現した植物の個体数

- 調査区画はふたつだけ 反復ぐらいとれよ……
- まず、ふたつの調査区を「さら地」にした
- 片方の調査区で何らかの「処理」(水やりとか?)
 - 無処理区 ($x = 0$) と処理区 ($x = 1$)
- ある時点で出現した植物を、種 (Spc) ごとにカウント
- とりあえず、個体数の多かった A 種 と B 種について調べることにした — 個体数 $\{y_{A,0}, y_{B,0}, y_{A,1}, y_{B,1}\}$
- 知りたいこと: 「処理」によって A 種・B 種の割合は変わるのか?
えー……「割合」だけ?

R で分割表をあつかう

`data.frame()` と `xtabs()`

データを CSV ファイルとして出力

	A	B	C
1	y	x	Spc
2	286	0	A
3	85	0	B
4	378	1	A
5	148	1	B
6			

- 「CSV」として保存 (脱 炉くせる!)
- d2.csv というファイル名にする
- d2.csv の内容
 - y,x,Spc
 - 286,0,A
 - 85,0,B
 - 378,1,A
 - 148,1,B

データを R によみこみ, data.frame に変換

```
> d2 <- read.csv("d2.csv") # よみこんで, data.frame  
変換!
```

```
> d2 # d2 という data.frame を表示
```

	y	x	Spc
1	286	0	A
2	85	0	B
4	378	1	A
5	148	1	B

xtabs: 分割表をあつかう R のクラス

	y	x	Spc
1	286	0	A
2	85	0	B
4	378	1	A
5	148	1	B

```
> (ct2 <- xtabs(y ~ x + Spc, data = d2))
```

	Spc	
x	A	B
0	286	85
1	378	148

xtabs: 自由自在に集計できる

```
> xtabs(y ~ x, data = d2)
x
  0   1
371 526

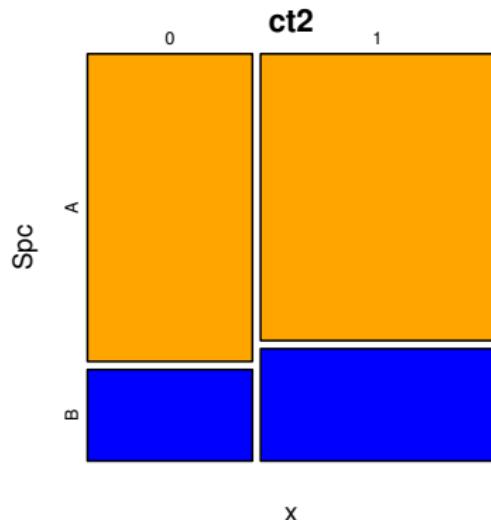
> xtabs(y ~ Spc, data = d2)
Spc
  A   B
664 233

> xtabs(y ~ Spc + x, data = d2)
          x
Spc 0   1
  A 286 378
  B 85 148
```

xtabs: 分割表の図示

Spc	A	B
x	286	85
0	378	148

```
> plot(ct2, col = c("orange", "blue"))
```



library(lattice) を使った図示

Spc

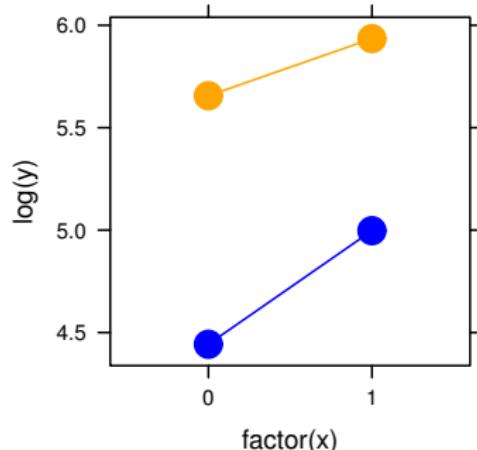
x A B

0 286 85

1 378 148

> library(lattice)

> xyplot(log(y) ~ factor(x), data = d2, groups = Spc, type = "b")



2 × 2 分割表の統計モデル
まずは二項分布の GLM から
ロジスティック回帰 logistic regression

二項分布の GLM を適用してみる

$$y_{A,x} \sim \text{Binom}(q_{A,x}, y_{A,x} + y_{B,x})$$

$$\text{logit}(q_{A,x}) = a_A + b_A x$$

Spc

x	A	B
0	286	85
1	378	148

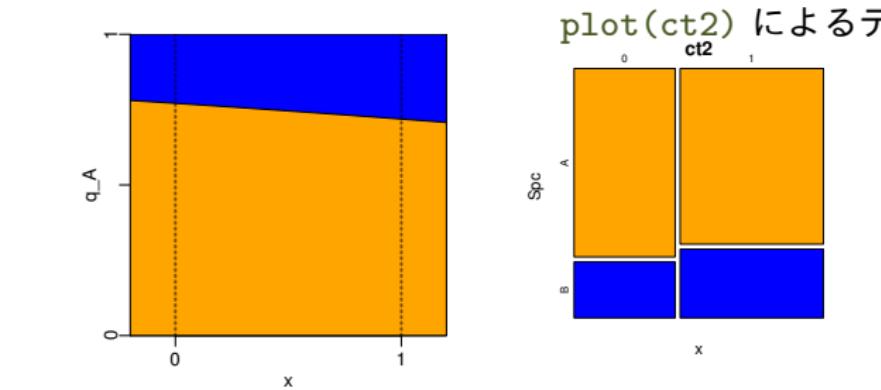
```
> summary(glm(ct2 ~ c(0, 1), data = d2, family = binomial))
```

(... 略 ...)

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	1.213	0.124	9.82	<2e-16
c(0, 1)	-0.276	0.157	-1.76	0.079

ロジスティック回帰の推定にもとづく予測

$$\text{logit}(q_{A,x}) = 1.213 + (-0.276)x$$



モデル	AIC
x に依存する $\text{logit}(q_{A,x}) = a_A + b_B x$	16.5
x に依存しない $\text{logit}(q_{A,x}) = a_A$	17.6

2 × 2 分割表の統計モデル

次にポアソン分布の GLM であつかってみる

とりあえず「分割方式」で

ポアソン回帰 Poisson regression

対数線形モデル log-linear model

ポアソン分布の GLM (分割方式) — A 種

$$y_{A,x} \sim \text{Pois}(\lambda_{A,x})$$

$$\log(\lambda_{A,x}) = \alpha_A + \beta_A x$$

```
> # SpcA だけ
> summary(glm(y ~ x, data = d2[d2$Spc == "A",], family = poisson)
(... 略...)
      Estimate Std. Error z value Pr(>|z|)
(Intercept)  5.6560    0.0591  95.65 < 2e-16
x            0.2789    0.0784   3.56  0.00037
```

ポアソン分布の GLM (分割方式) — B 種

$$y_{B,x} \sim \text{Pois}(\lambda_{B,x})$$

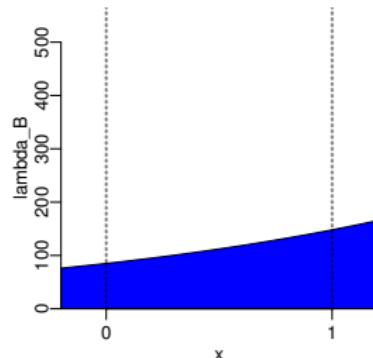
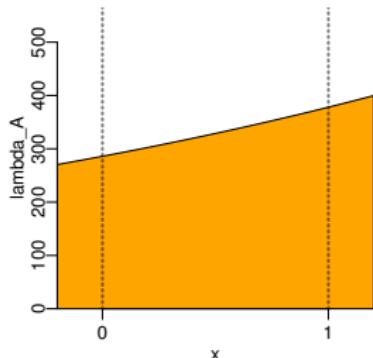
$$\log(\lambda_{B,x}) = \alpha_B + \beta_B x$$

```
> # SpcB だけ
> summary(glm(y ~ x, data = d2[d2$Spc == "B",], family = poisson)
(... 略...)
      Estimate Std. Error z value Pr(>|z|)
(Intercept) 4.443      0.108   40.96 < 2e-16
x            0.555      0.136    4.07  4.6e-05
```

ポアソン回帰の推定にもとづく予測

$$\log(\lambda_{A,x}) = 5.66 + 0.279x$$

$$\log(\lambda_{B,x}) = 4.44 + 0.555x$$



モデル	AIC	モデル	AIC
$\lambda_{A,x} = \alpha_A + \beta_A x$	19.3	$\lambda_{B,x} = \alpha_B + \beta_B x$	17.1
$\lambda_{A,x} = \alpha_A$	30.1	$\lambda_{B,x} = \alpha_B$	32.4

ポアソン分布 GLM・二項分布 GLM のつながり

- 二項分布 GLM: $\text{logit}(q_{A,x}) = \alpha_A + \beta_A x$

$$q_{A,x} = \frac{1}{1 + \exp[-(\alpha_A + \beta_A x)]}$$

- ポアソン分布: $\log(\lambda_{A,x}) = \alpha_A + \beta_A x$ など

$$\lambda_{A,x} = \exp(\alpha_A + \beta_A x)$$

$$\lambda_{B,x} = \exp(\alpha_B + \beta_B x)$$

…… 「A 種の割合」は？

$$\begin{aligned}\frac{\lambda_{A,x}}{\lambda_{A,x} + \lambda_{B,x}} &= \frac{\exp(\alpha_A + \beta_A x)}{\exp(\alpha_A + \beta_A x) + \exp(\alpha_B + \beta_B x)} \\ &= \frac{1}{1 + \exp[\alpha_B - \alpha_A + (\beta_B - \beta_A)x]}\end{aligned}$$

係数の比較: ポアソン分布 GLM・二項分布 GLM のつながり

二項分布の GLM

$$q_{A,x} = \frac{1}{1 + \exp[-(a_A + b_A x)]}$$

ポアソン分布の GLM (分割方式)

$$\frac{\lambda_{A,x}}{\lambda_{A,x} + \lambda_{B,x}} = \frac{1}{1 + \exp[\alpha_B - \alpha_A + (\beta_B - \beta_A)x]}$$

比較すると……

二項分布 GLM

ポアソン分布 GLM

$$a_A = \alpha_A - \alpha_B$$

$$b_A = \beta_A - \beta_B$$

比較: 二項分布とポアソン分布の GLM

二項分布 GLM

$$a_A = 1.213 =$$

$$b_A = -0.276 =$$

ポアソン分布 GLM

$$\alpha_A - \alpha_B$$

$$\beta_A - \beta_B$$

> 二項分布 GLM (A 種の比率)

```
> glm(ct2 ~ c(0, 1), data = d2, family = binomial)
```

```
(Intercept) c(0, 1)
```

```
1.213 -0.276
```

> ポアソン分布 GLM (A 種の比率)

```
> glm(y ~ x, data = d2[d2$Spc == "A", ], family = poisson)
```

```
(Intercept) x
```

```
5.656 0.279
```

> ポアソン分布 GLM (B 種の比率)

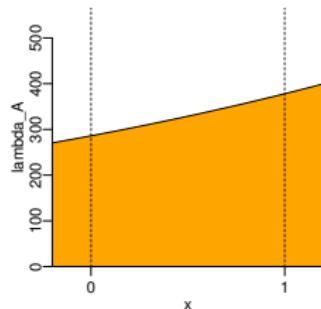
```
> glm(y ~ x, data = d2[d2$Spc == "B", ], family = poisson)
```

```
(Intercept) x
```

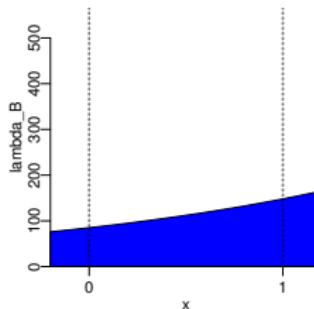
```
4.443 0.555
```

図解: ポアソン分布 GLM・二項分布 GLM のつながり

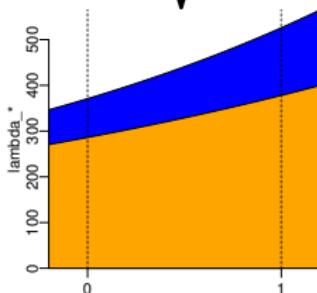
ポアソン分布の GLM (A 種)



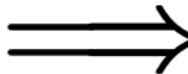
ポアソン分布の GLM (B 種)



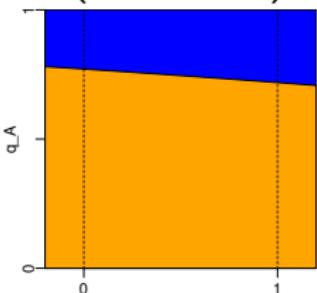
つみあげる



たいらに
押しつぶす



二項分布の GLM
(A 種 + B 種)



2×2 分割表の統計モデル

データを分割しないポアソン分布 GLM

「一括方式」 — こちらが便利かも？

ポアソン分布の GLM (一括方式)

交互作用項をうまく利用する

```
> summary(glm(y ~ x * Spc, data = d2, family = poisson))  
(... 略...)
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	5.6560	0.0591	95.65	< 2e-16
x	0.2789	0.0784	3.56	0.00037
SpcB	-1.2133	0.1235	-9.82	< 2e-16
x:SpcB	0.2757	0.1570	1.76	0.07921
(... 略...)				

「分割方式」のポアソン分布 GLM と一致 → 二項分布 GLM とも一致

$$\alpha_A = 5.66$$

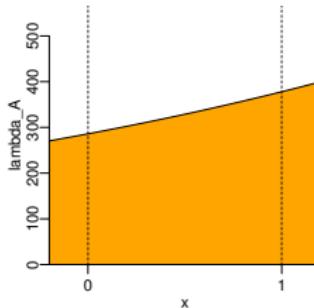
$$\alpha_B = 5.66 - 1.21$$

$$\beta_A = 0.279$$

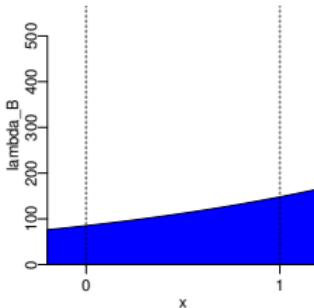
$$\beta_B = 0.279 + 0.276$$

ポアソン・二項分布両 GLM のつながり (再)

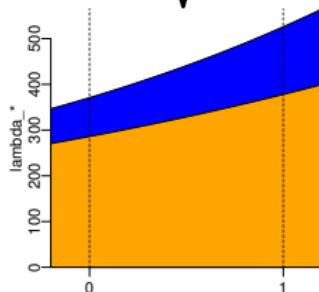
ポアソン分布の GLM (A 種)



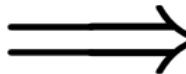
ポアソン分布の GLM (B 種)



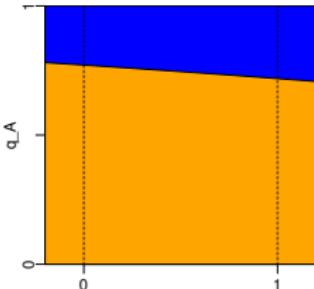
つみあげる



たいらに
押しつぶす



二項分布の GLM
(A 種 + B 種)



2×3 の分割表

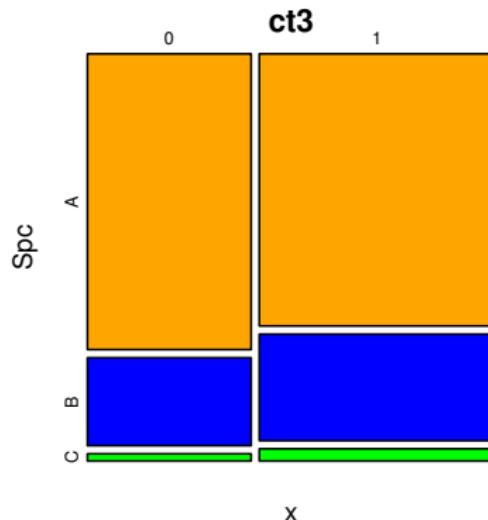
多項分布の GLM か?

ポアソン分布の GLM か?

xtabs: 分割表の図示

Spc	A	B	C
x	286	85	7
0	286	85	7
1	378	148	17

```
> plot(ct3, col = c("orange", "blue", "green"))
```



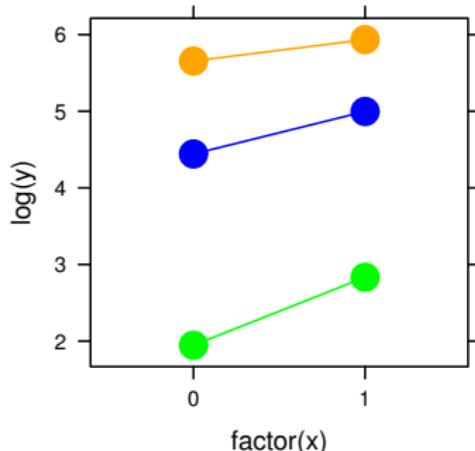
library(lattice) を使った図示

Spc

x	A	B	C
0	286	85	7
1	378	148	17

```
> library(lattice)
```

```
> xyplot(log(y) ~ factor(x), data = d3, groups = Spc, type = "b")
```



ポアソン分布の GLM (一括方式)

```
> glm(y ~ x * Spc, data = d3, family = poisson)
```

(... 略...)

Coefficients:

(Intercept)	x	SpcB	SpcC	x:SpcB	x:SpcC
5.656	0.279	-1.213	-3.710	0.276	0.608

「分割方式」のポアソン分布 GLM のパラメーターで言うと……

$$y_{A,x} \sim \text{Pois}(\lambda_{A,x})$$

$$\log(\lambda_{A,x}) = \alpha_A + \beta_A x$$

$$\alpha_A = 5.66$$

$$\alpha_B = 5.66 - 1.21$$

$$\alpha_C = 5.66 - 3.71$$

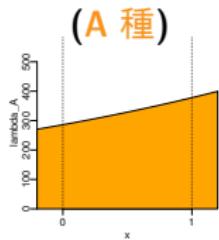
$$\beta_A = 0.279$$

$$\beta_B = 0.279 + 0.276$$

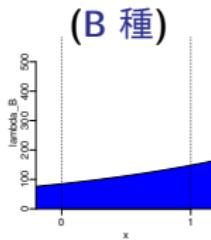
$$\beta_C = 0.279 + 0.608$$

ポアソン分布 GLM の予測など

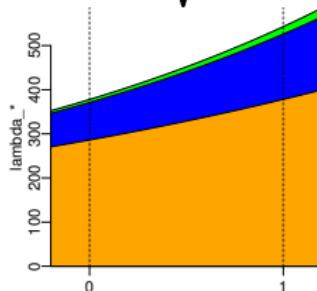
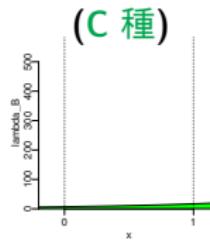
ポアソン分布の GLM



+

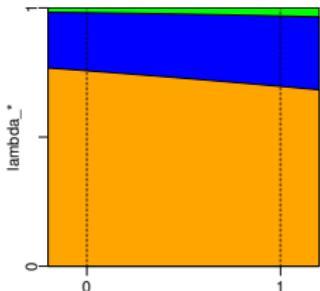


+



たいらに
押しつぶす

A large right-pointing arrow with the Japanese character 'たいらに押しつぶす' (Flatten) written next to it, indicating the transformation of the stacked plot into a single smooth curve.



二項分布 GLM を拡張した多項分布 GLM

library(nnet) の multinom()

多項分布・ロジスティックな GLM

```
> ct3 # 分割表を表示
```

x	A	B	C
0	286	85	7
1	378	148	17

```
> library(nnet) # nnet package よみこみ
```

```
> multinom(ct3 ~ c(0, 1))
```

(... 略...)

多項分布・ロジスティック GLM

Coefficients:

(Intercept) c(0, 1)
B -1.2133 0.27552
C -3.7097 0.60763

$y_{B,x} \sim \text{Multinom}(q_{B,x}, 3 \text{ 種合計})$

$y_{C,x} \sim \text{Multinom}(q_{C,x}, 3 \text{ 種合計})$

$$\begin{aligned}\text{logit}(q_{B,x}) &= a_B + b_B x \\ \text{logit}(q_{C,x}) &= a_C + b_C x\end{aligned}$$

```
> # ポアソン分布 GLM と同じ推定値!
```

モデル選択はどうする?

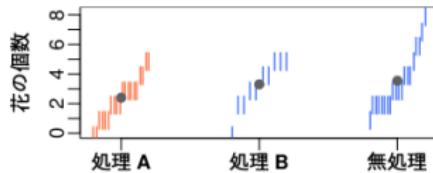
- すべての可能なくみあわせて調べるしかない
 - cf. 2004 年データ解析自由集会の久保発表

5. モデル選択基準が最良のものを採用する

すべてのグループわけについて AIC を計算する.

```
> results <- estimate.poisson(samples)
> cat(sapply(results, function(r)
  sprintf("Model %-12s, AIC = %.1f", r$tag, r$glm$aic)),
  sep = "\n")
```

Model (A+B+C)	, AIC = 195.5
Model (A+B) (C)	, AIC = 194.7
Model (A+C) (B)	, AIC = 197.3
Model (A) (B+C)	, AIC = 192.9
Model (A) (B) (C)	, AIC = 194.8



AIC 最小のモデルを選ぶ

2×9 の分割表

……そろそろ GLM ではしんどくなってくる?

また別のデータ: 種数が 3 から 9 に増えた!

```
> d9
```

	y	x	Spc
--	---	---	-----

1	62	0	A
---	----	---	---

2	21	0	B
---	----	---	---

3	14	0	C
---	----	---	---

4	11	0	D
---	----	---	---

5	10	0	E
---	----	---	---

6	10	0	F
---	----	---	---

7	2	0	G
---	---	---	---

8	0	0	H
---	---	---	---

9	2	0	I
---	---	---	---

10	48	1	A
----	----	---	---

(... 略...)

15	7	1	F
----	---	---	---

16	2	1	G
----	---	---	---

17	1	1	H
----	---	---	---

18	1	1	I
----	---	---	---

```
> ct9
```

	Spc
--	-----

x	A	B	C	D	E	F	G	H	I
---	---	---	---	---	---	---	---	---	---

0	62	21	14	11	10	10	2	0	2
---	----	----	----	----	----	----	---	---	---

1	48	34	22	17	16	7	2	1	1
---	----	----	----	----	----	---	---	---	---

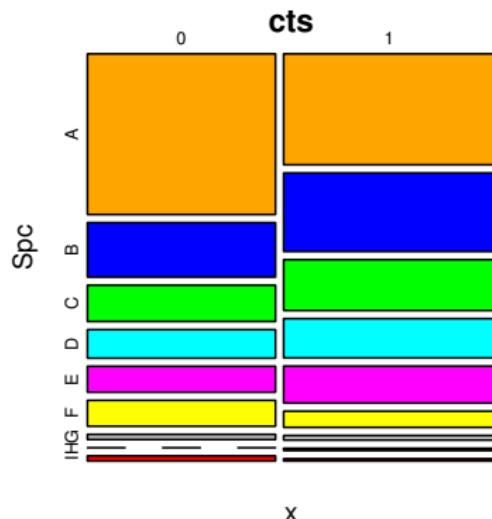
- 種ごとに個体数のばらつきがかなりある

- ゼロデータを含む

xtabs: 分割表の図示

Spc	x	A	B	C	D	E	F	G	H	I
0	62	21	14	11	10	10	2	0	2	
1	48	34	22	17	16	7	2	1	1	

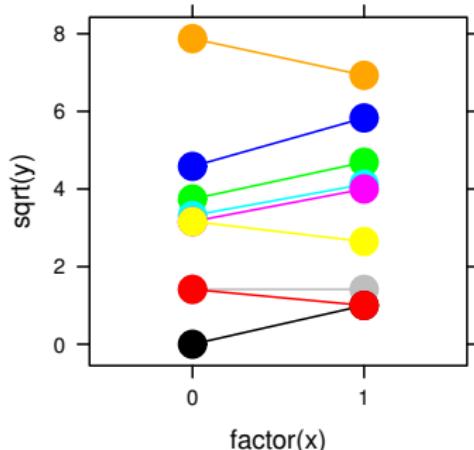
```
> plot(ct9, col = c(ごちゃごちゃと指定))
```



library(lattice) を使った図示

Spc	A	B	C	D	E	F	G	H	I
x	62	21	14	11	10	10	2	0	2
0	48	34	22	17	16	7	2	1	1

```
> library(lattice)
> xyplot(sqrt(y) ~ factor(x), data = d9, groups = Spc, type = "b")
```



ポアソン分布の GLM (一括方式)

```
> ct9
```

	Spc	x	A	B	C	D	E	F	G	H	I
0	62	21	14	11	10	10	2	0	2		
1	48	34	22	17	16	7	2	1	1		

```
> summary(glm(y ~ x * Spc, data = d9, family = poisson))
```

(Intercept)	x	SpcB	SpcC
4.127	-0.256	-1.083	-1.488
SpcD	SpcE	SpcF	SpcG
-1.729	-1.825	-1.825	-3.434
SpcH	SpcI	x:SpcB	x:SpcC
-26.430	-3.434	0.738	0.708
x:SpcD	x:SpcE	x:SpcF	x:SpcG
0.691	0.726	-0.101	0.256
x:SpcH	x:SpcI		
22.559	-0.437		

H 種 の推定値がかなりヘン!

「なんでも `glm()`」方針の問題点

- 分割表がでかくなったりしたときに、独立に推定されるパラメーター数がどんどん増えてしまう
- そのような場合、とくにゼロデータなどがあると、パラメーター推定が難しくなる
- モデル選択とかもしんどくなる

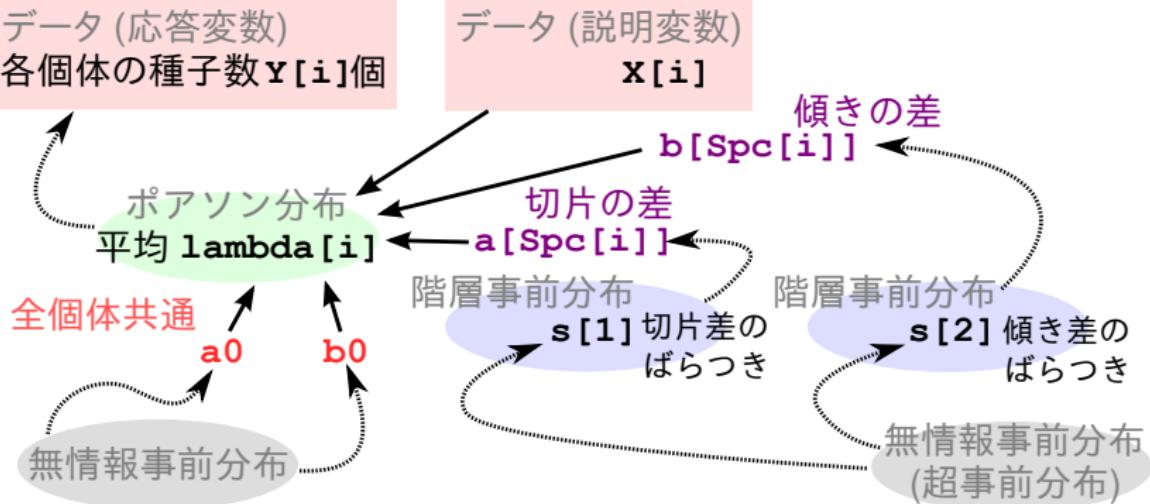
ポアソン分布の GLMM ならどうだろう?

```
> (fit.glmm <- glmmML(y ~ x, data = d9, cluster = Spc, family = poisson))

            coef  se(coef)      z Pr(>|z|)
(Intercept) 2.012    0.465 4.323  1.5e-05
x           0.114    0.120 0.956  3.4e-01

> fit.glmm$posterior.modes
[1]  1.926862  1.230935  0.807098  0.557225  0.483854
[6]  0.067305 -1.218522 -2.005846 -1.426968
```

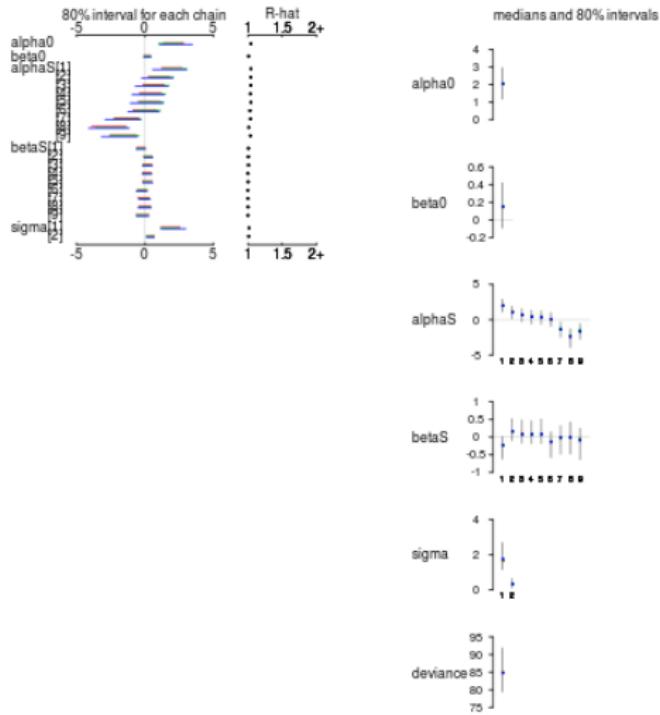
分割表の階層ベイズモデル (線形ポアソン回帰)



- このようにデータを設計する
- WinBUGS を使ってパラメーター推定 (MCMC 法) をしたいので、BUGS コードで書く
- WinBUGS を R の下っばとして使う

(時間があれば WinBUGS 実演)

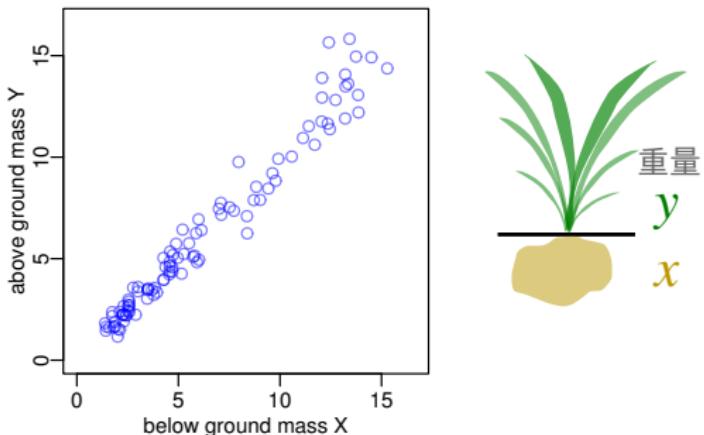
s model at "/home/kubo/public_html/oe/2012/model.bug.txt", fit using WinBUGS, 3 chains, each with 6000 iterations (first 1000 discarded)



例題 1

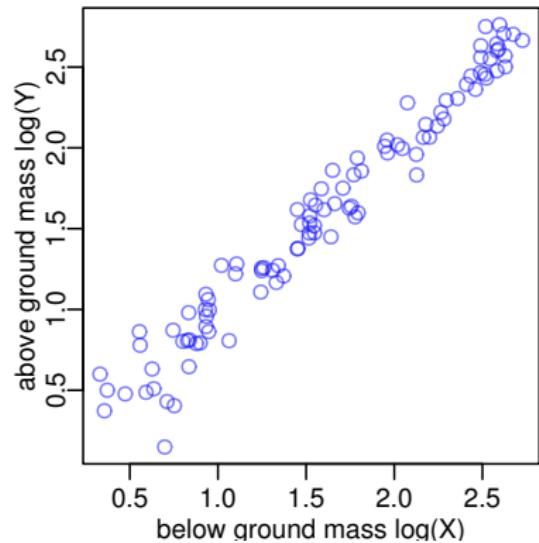
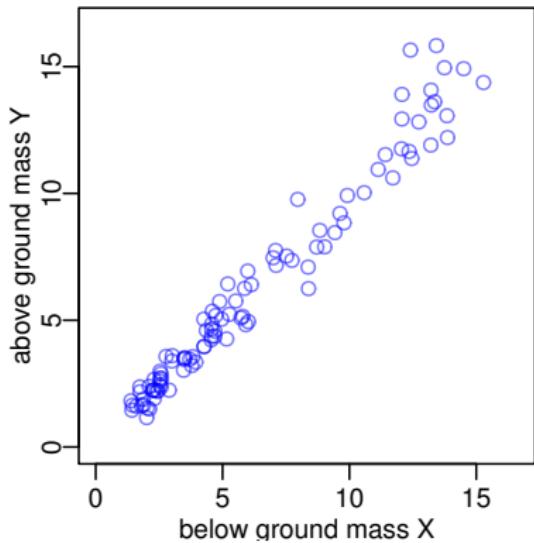
「アロメトリーな回帰」はやめて
重量分割モデルを作ってみよう

架空データ 1: 地下部・地上部の重量



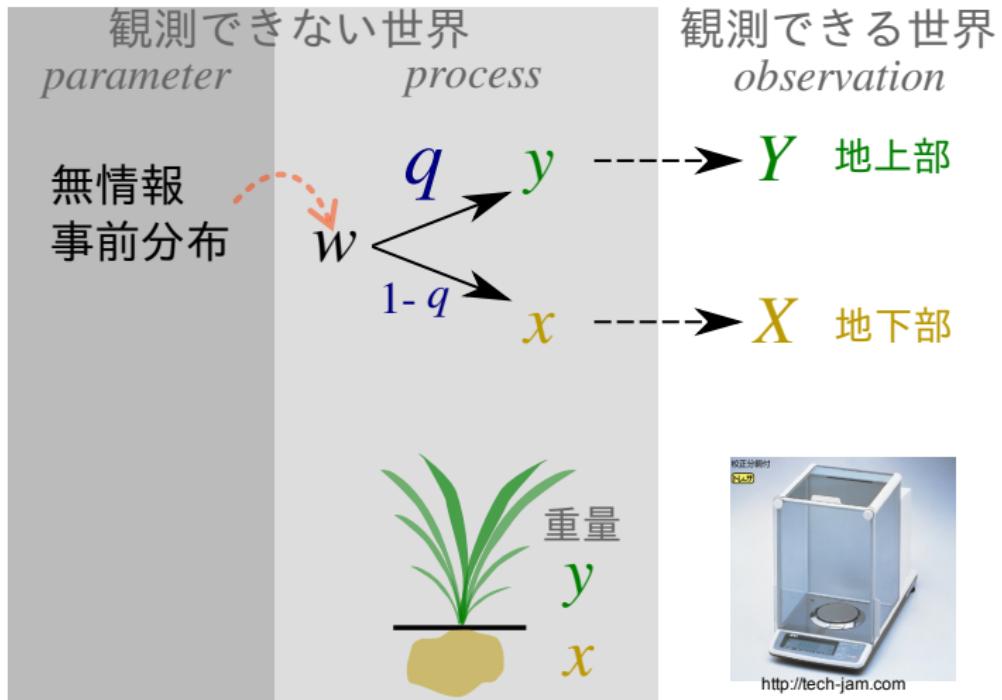
- 対数をとらなくても「直線」にのってる?
- つまり、むしろアイソメトリック (isometric)?
- 重量が重くなるとばらつきが大きくなる?

対数スケールでみるとこうなってます

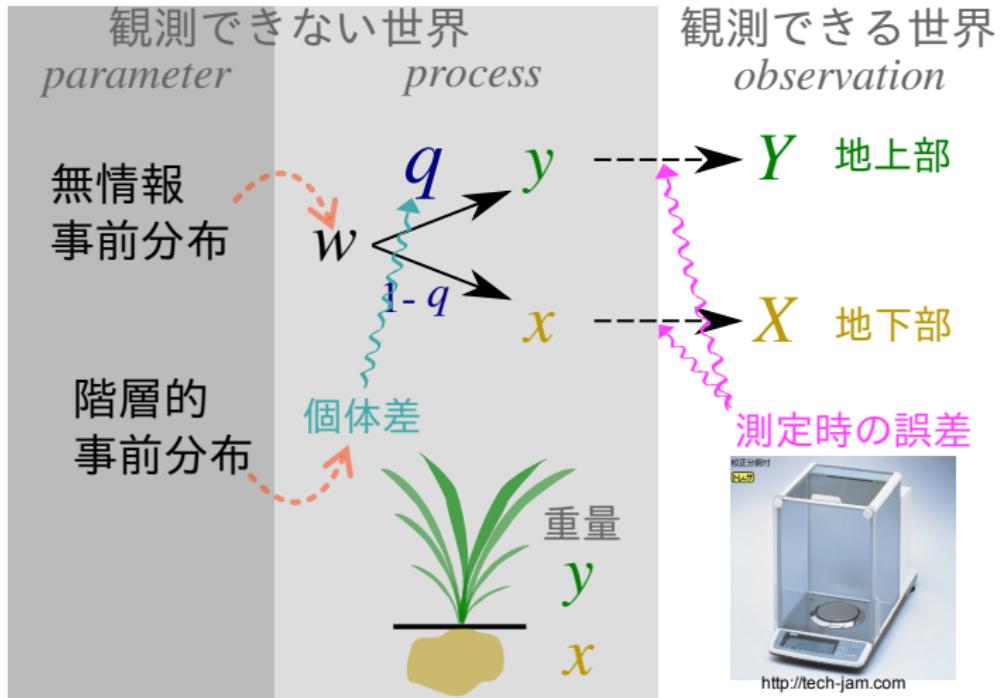


- とはいえ対数世界で「センをひっぱる」わけではない

重量分割モデル (階層ベイズモデル): そのプロセス



重量分割モデル (階層ベイズモデル): 「誤差」の入りかた



重量分配モデルを BUGS code で (process の部分のみ)

```
for (i in 1:N) {  
    Y[i] ~ dnorm(y[i], Tau.err) # 地上部の重量  
    X[i] ~ dnorm(x[i], Tau.err) # 地下部の重量  
    y[i] <- q[i] * w[i]  
    x[i] <- (1 - q[i]) * w[i]  
    logit(q[i]) <- a + re[i]  
    w[i] <- exp(log.w[i])  
    log.w[i] ~ dnorm(0, Tau.noninformative) # !!  
}# log.w[i] は地上部 + 地下部の重量
```

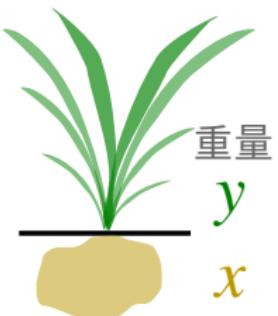
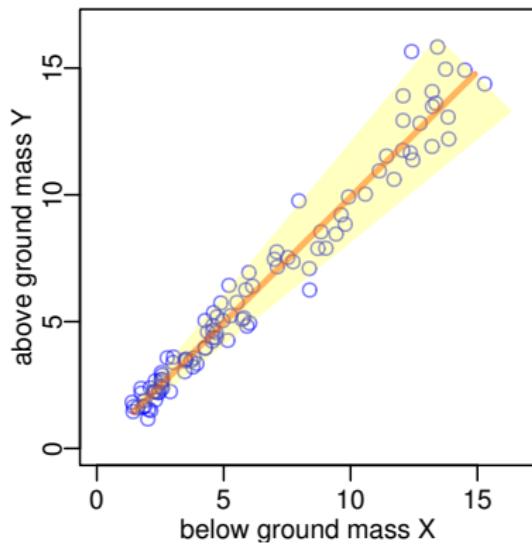
このように明示的にモデルを記述できる!

階層ベイズモデルのパラメーター推定: MCMC

1. BUGS code で重量分割モデルを記述する (model1.txt)
2. これにデータを渡したりする R スクリプトを書く
(runbus1.R)
3. R で runbus1.R を実行 (source("runbugs1.R"))
4. R 内から library(R2WinBUGS) によって WinBUGS が起動
5. WinBUGS 内で Markov chain Monte Carlo (MCMC) サンプリング
6. 事後分布からのサンプリング結果が R に渡される

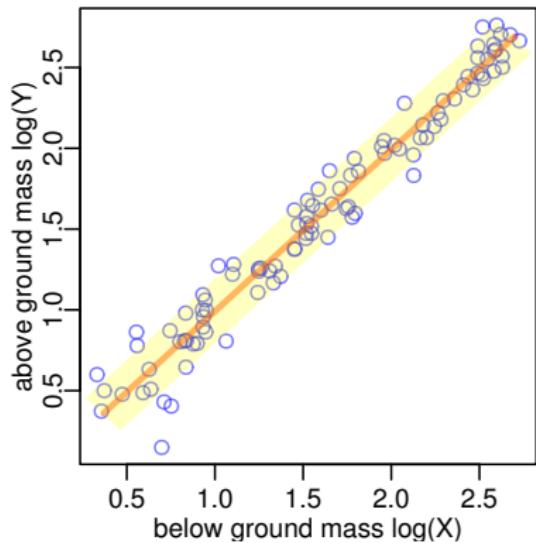
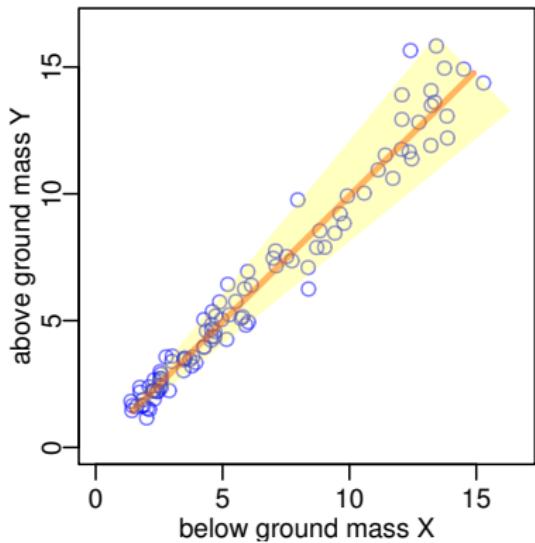
必要なファイルは自由集会サイトからダウンロードできます

推定結果を組みあわせた予測



- オレンジ色の線は中央値 (median)
- 黄色の領域は個体差による予測のばらつき (95% CI)

個体差によるばらつき，そして測定時の誤差



- 総重量が小さいときには測定時の誤差が相対的に大きくなる
- 総重量が大きくなると個体差が占める割合が大きくなる

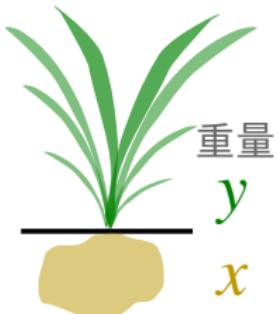
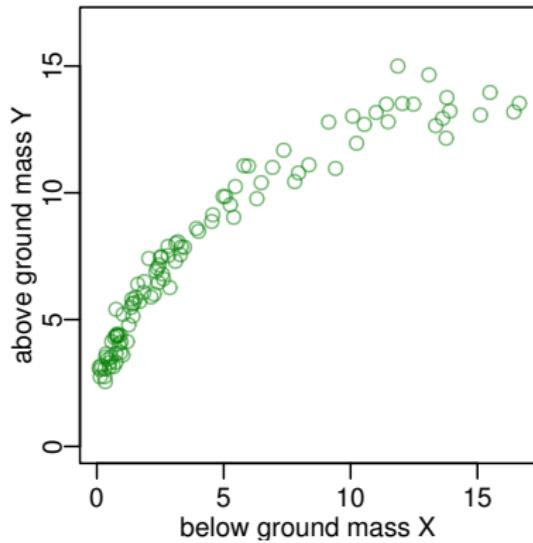
このモデルの問題点

- 測定時の誤差は正規分布と仮定していいのか?
 - そうですね，重量は非負の値なのに.....
- 測定時の誤差の大きさはどうやって推定したの?
 - 今回は「真の値」をほうりこみました
 - 実際には，測定機器のカタログとか見ながら「てきとー」に決め
るしかないのかも？(主観的な事前分布)
 - ひとつの観測対象に対して，複数の測定値が得られていれば，階
層ベイズモデルで測定時の誤差の大きさを推定できます
- 状況がちょっと単純すぎない?
 - それでは次の例題を.....

例題 2

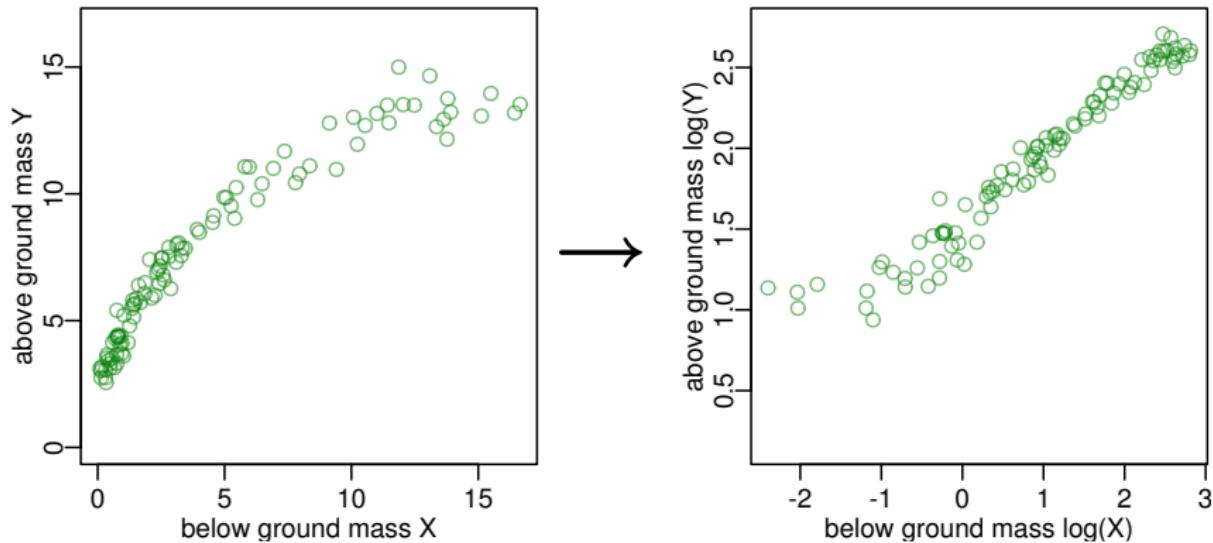
もうちょっと複雑な 重量分割モデル

架空データ 2: 重量増大とともに分配が変化



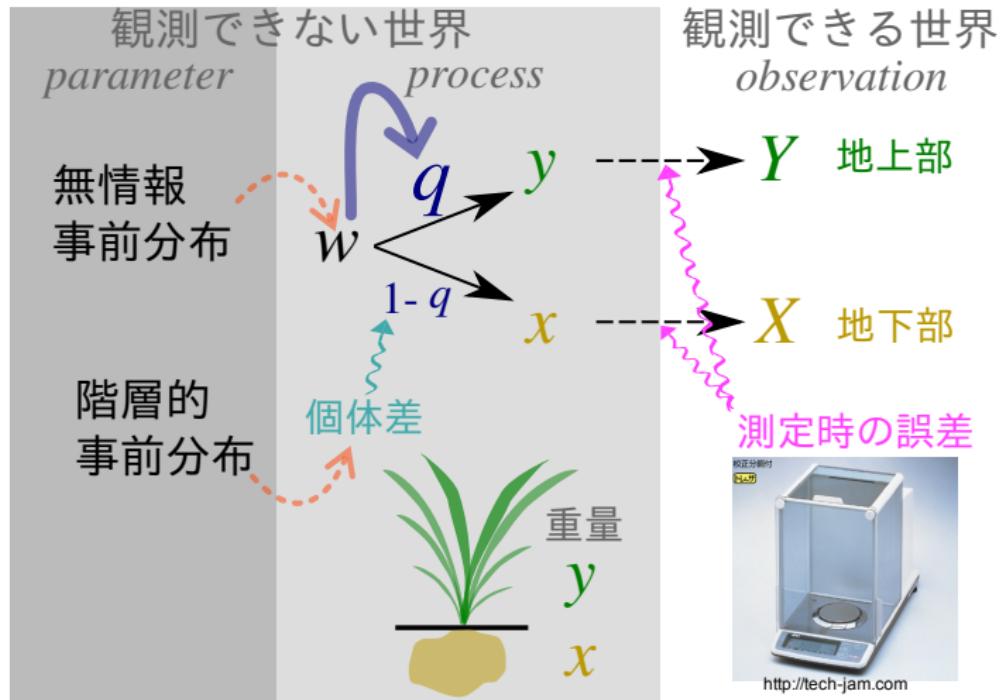
- 小さいときには地上部重量を大きくする
- 総重量が大きくなってくれば地下部を大きくする

これはアロメトリーな問題なのだろうか?



- 両対数で直線になっているのか?
- ま，それはあとで考えることにして.....

重量分割モデルの改造: q を w 依存にするだけ



BUGS code の変更点

- 先ほどの簡単な例では (切片) + (個体差) だったが

```
logit(q[i]) <- a + re[i]
```

- ここを以下のように総重量 (w) 依存に変更するだけ

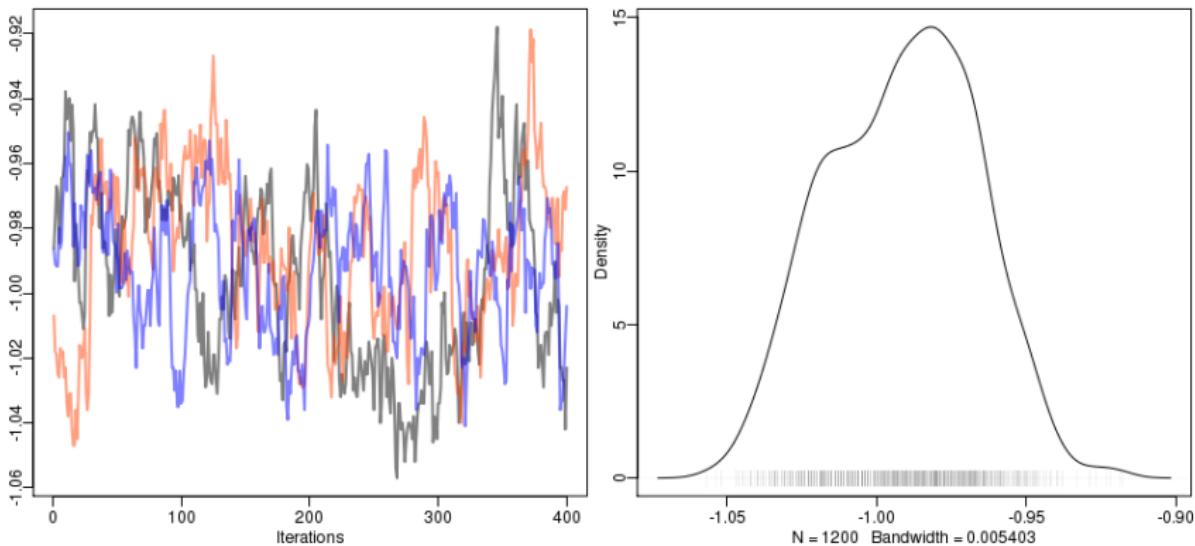
($b \sim dnorm(0, Tau.noninformative)$ 追加も必要だけど)

```
logit(q[i]) <- (
  a + b * (log.w[i] - Mean.log.w) + re[i]
)
```

Mean.log.w うんぬんは WinBUGS に必須な中央化ワザ

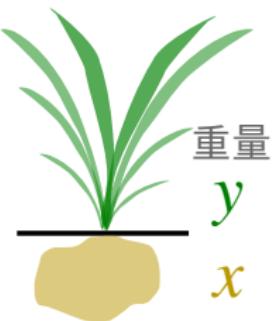
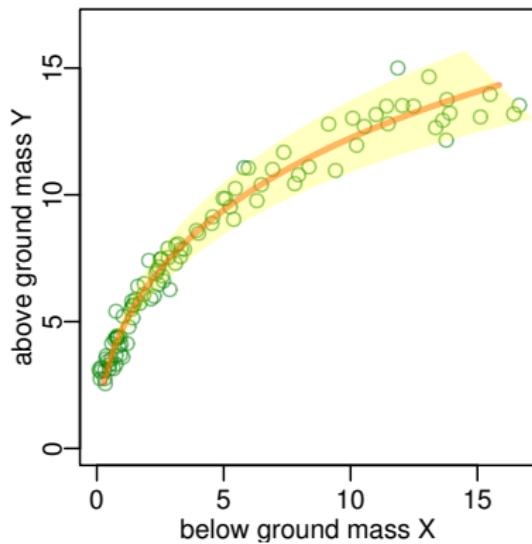
- あとは R と WinBUGS で MCMC するだけ

推定結果: 総重量増大 → 地上部への分配減少



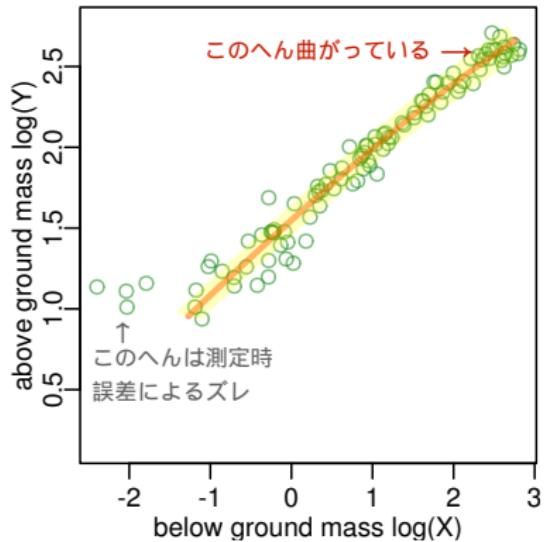
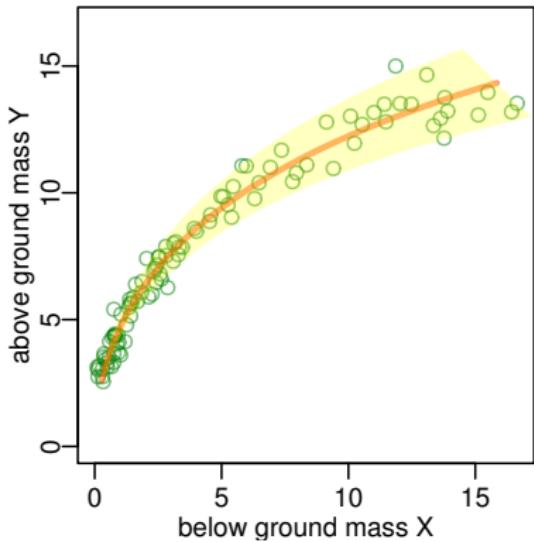
- 総重量 w 依存のパラメーター b はマイナス
- こういう問題は MCMC 収束が遅い

このモデルで複雑な重量分配を表現できる



- オレンジ色の線は中央値 (median)
- 黄色の領域は個体差による予測のばらつき (95% CI)

対数の世界でも曲がっている (アロメトリーじゃない!)



- 「両対数表示でも曲がっている」状況でも重量分配モデルは柔軟に対応できる（さらに改訂するのも簡単）

モデルの発展・応用

そしてまとめ

重量分配モデルの発展

- random effects 的な部分の複雑化
 - 個体差だけでなくブロック差・場所差・時系列構造・空間構造.....
- 分割数をふたつではなく **3つ以上にも** できる
- 蛇足 1: アロメトリーなモデル (べき乗式) より、重量分配モデルのほうが**解釈しやすい**モデルではなかろーか?
- 蛇足 2: 応答変数が離散値の場合は二項分布・多項分布モデルで (つまりふつーの二項・多項 logistic 回帰)