

統計モデリング入門 2017 (d)

モデル選択と検定

久保拓弥 kubo@ees.hokudai.ac.jp

北大環境科学院の講義 <http://goo.gl/76c4i>

2019-07-29

ファイル更新時刻: 2019-07-20 08:16

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 1 / 44

もくじ

今日のハナシ I

- ① 前回と同じ例題: 種子数データ
植物個体の属性, あるいは実験処理が種子数に影響?
- ② AIC を使ったモデル選択
あてはまりの悪さ: deviance
- ③ 統計学的な検定
そして, その非対称性
- ④ モデル選択と統計学的な検定
のさまざまな誤解

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 2 / 44

もくじ

今日の内容と「統計モデリング入門」との対応

今日はおもに「**第4章 GLMのモデル選択**」と「**第5章 GLMの尤度比検定と検定の非対称性**」の内容を説明します。

- 著者: 久保拓弥
- 出版社: 岩波書店
- 2012-05-18 刊行

<http:// goo.g1/Ufq2>

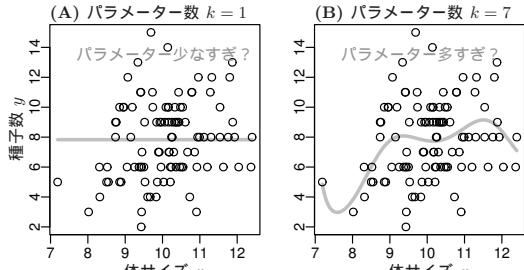
http:// goo.g1/Ufq2

統計と機械の科学
データ解析のための
統計モデリング入門
一般化線形モデル・階層ベイズモデル・MCMC
久保拓弥
岩波書店

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 3 / 44

もくじ

パラメーター数は多くても少なくともへン?



(A) パラメーター数 $k = 1$
パラメータ少なすぎ?

(B) パラメーター数 $k = 7$
パラメータ多すぎ?

How many parameters do you need for the best prediction?

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 4 / 44

前回と同じ例題: 種子数データ 植物個体の属性, あるいは実験処理が種子数に影響?

1. 前回と同じ例題: 種子数データ

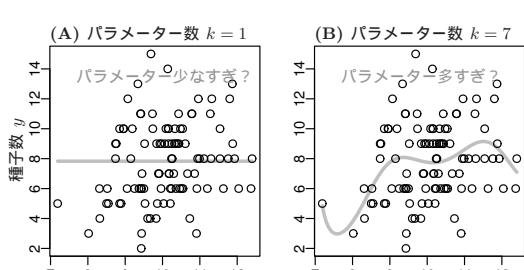
植物個体の属性, あるいは実験処理が種子数に影響?

まずはデータの概要を調べる

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 5 / 44

前回と同じ例題: 種子数データ 植物個体の属性, あるいは実験処理が種子数に影響?

パラメーター数 k は多くても少なくともへン?



(A) パラメーター数 $k = 1$
パラメータ少なすぎ?

(B) パラメーター数 $k = 7$
パラメータ多すぎ?

“良いモデル”? number of parameters k ?

kubostat2017d (<http://goo.gl/76c4i>) 統計モデリング入門 2017 (d) 2019-07-29 6 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

個体サイズと実験処理の効果を調べる例題

- 応答変数: 種子数 $\{y_i\}$
- 説明変数:
 - 体サイズ $\{x_i\}$
 - 施肥処理 $\{f_i\}$

標本数

- 無処理 ($f_i = C$): 50 sample ($i \in \{1, 2, \dots, 50\}$)
- 施肥処理 ($f_i = T$): 50 sample ($i \in \{51, 52, \dots, 100\}$)

個体 i
施肥処理 f_i
C: 肥料なし
T: 施肥処理
種子数 y_i
体サイズ x_i

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 7 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

この例題のための統計モデル

ポアソン回帰のモデル

- 確率分布: ポアソン分布
- 線形予測子: $\beta_1 + \beta_2 x_i + \beta_3 f_i$
- リンク関数: 対数リンク関数

Y-axis: \hat{y}_i
X-axis: x_i

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 8 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

4 つの可能なモデル候補: (A) constant λ

$$\lambda_i = \exp(\beta_1)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ 1, data = d, family = poisson))
'log Lik.' -237.64 (df=1)
```

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 9 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

4 つの可能なモデル候補: (B) f model

$$\lambda_i = \exp(\beta_1 + \beta_3 f_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ f, data = d, family = poisson))
'log Lik.' -237.63 (df=2)
```

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 10 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

4 つの可能なモデル候補: (C) x model

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x, data = d, family = poisson))
'log Lik.' -235.39 (df=2)
```

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 11 / 44

前回と同じ例題: 種子数データ 植物個体の属性 , あるいは実験処理が種子数に影響?

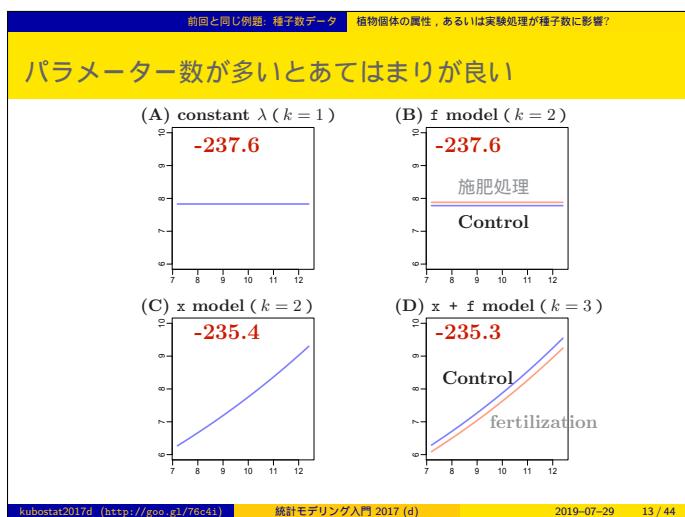
4 つの可能なモデル候補: (D) x + f model

$$\lambda_i = \exp(\beta_1 + \beta_2 x_i + \beta_3 f_i)$$

あてはまりの良さを対数尤度 (log likelihood) で評価する

```
> logLik(glm(y ~ x + f, data = d, family = poisson))
'log Lik.' -235.29 (df=3)
```

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 12 / 44



AIC を使ったモデル選択：あてはまりの悪さ: deviance

2. AIC を使ったモデル選択

あてはまりの悪さ: deviance

そして予測の悪さ: AIC

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 14 / 44

AIC を使ったモデル選択：あてはまりの悪さ: deviance

R の `glm()` は deviance を出力

```
> glm(y ~ x + f, data = d, family = poisson)

Call: glm(formula = y ~ x + f, family = poisson, data = d)

Coefficients:
(Intercept)          x           fT 
      1.2631     0.0801    -0.0320 

Degrees of Freedom: 99 Total (i.e. Null); 97 Residual
Null Deviance: 89.5
Residual Deviance: 84.8      AIC: 477

Residual Deviance? Null Deviance? AIC?
```

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 15 / 44

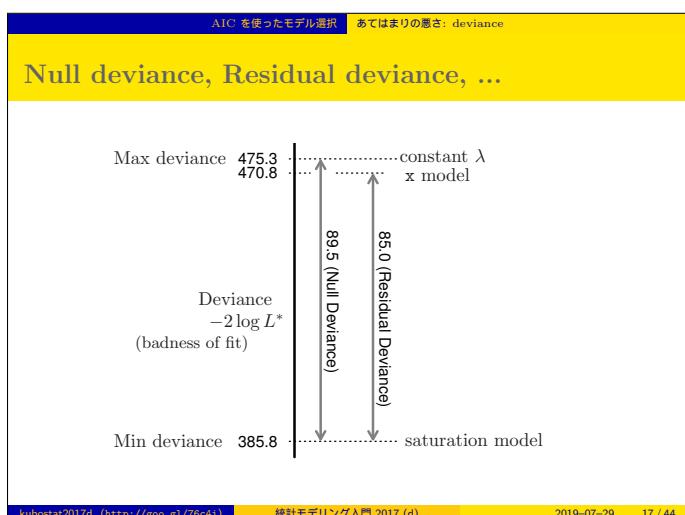
AIC を使ったモデル選択：あてはまりの悪さ: deviance

$deviance D = -2 \times \log L^*$

- Maximum log likelihood $\log L^*$: goodness of fit
- Deviance $D = -2 \log L^*$: badness of fit

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance
constant λ	1	-237.6	475.3	89.5
f	2	-237.6	475.3	89.5
x	2	-235.4	470.8	85.0
$x + f$	3	-235.3	470.6	84.8
saturation	100	-192.9	385.8	0.0

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 16 / 44



AIC を使ったモデル選択：あてはまりの悪さ: deviance

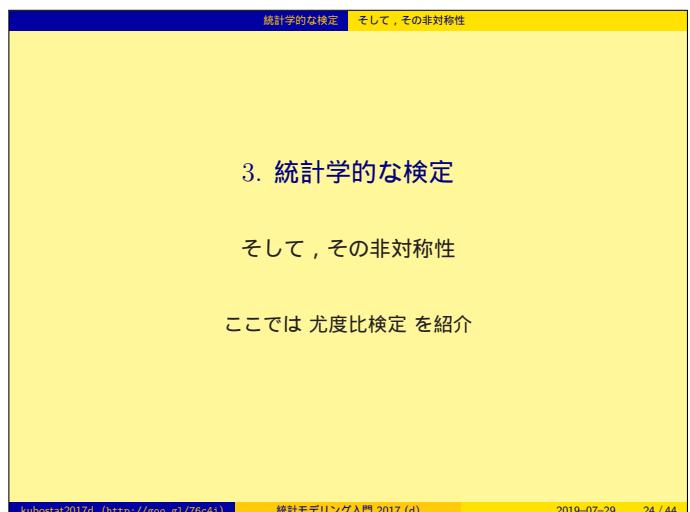
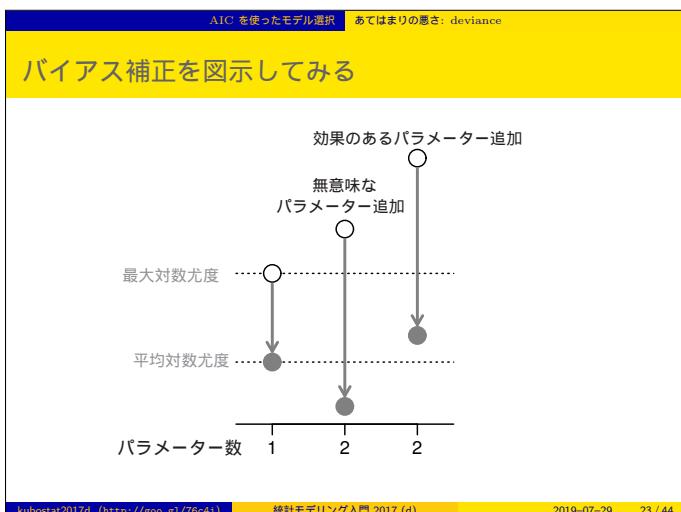
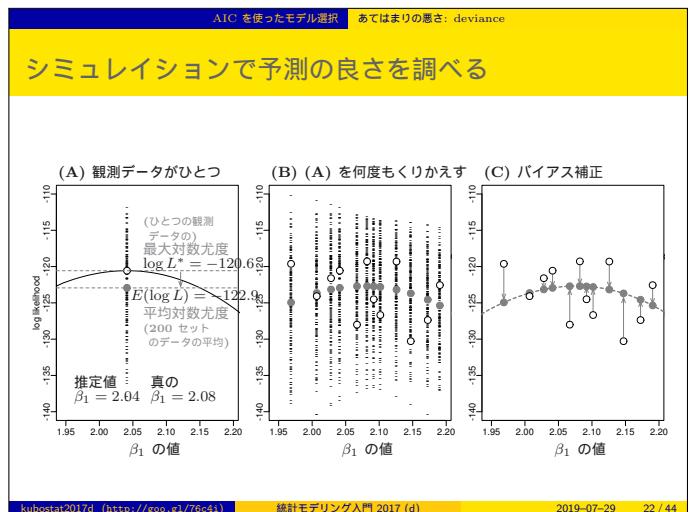
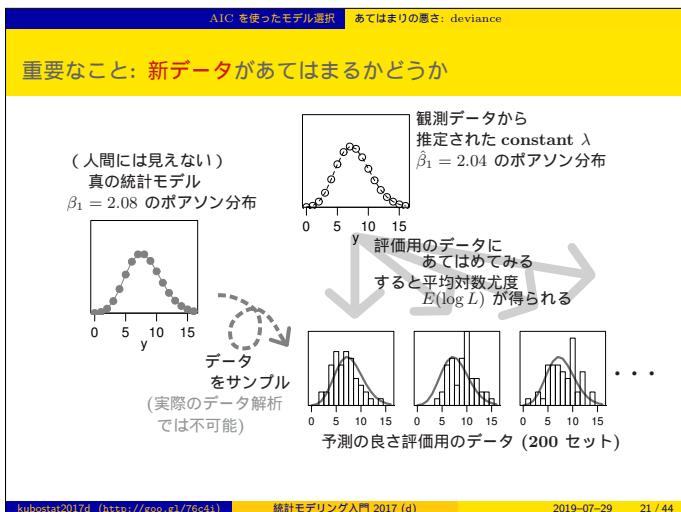
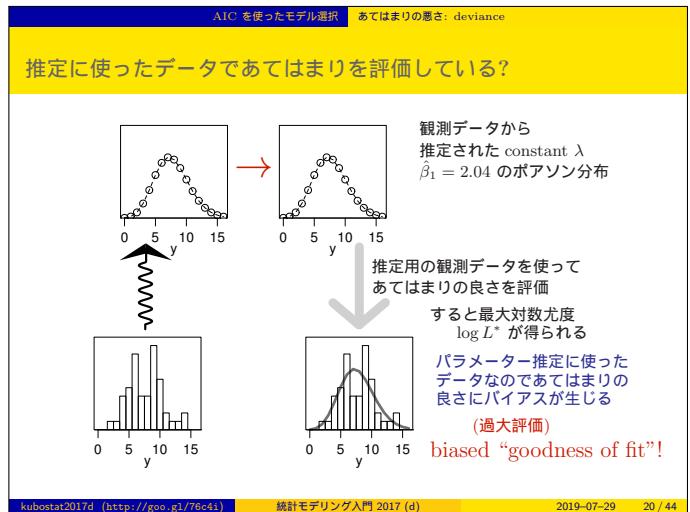
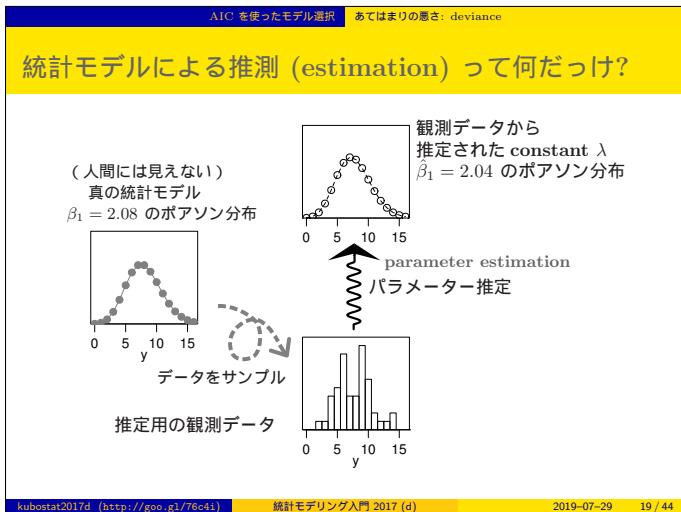
予測の悪さ: $AIC = -2 \log L^* + 2k$

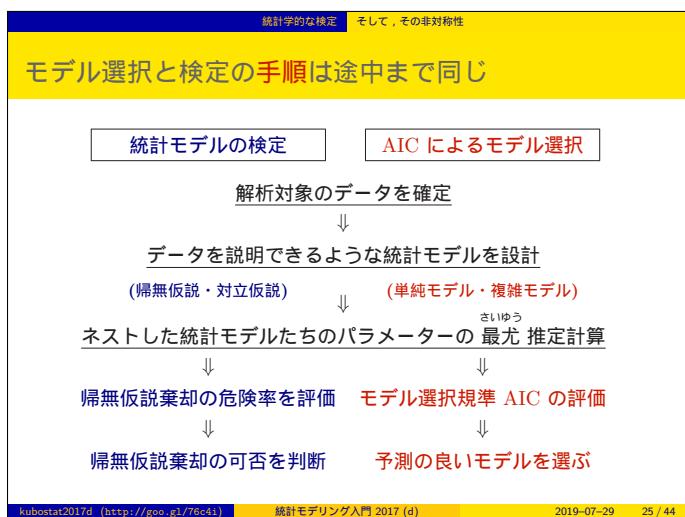
AIC 最小のモデルを選ぶ

model	k	$\log L^*$	Deviance $-2 \log L^*$	Residual deviance	AIC
constant λ	1	-237.6	475.3	89.5	477.3
f	2	-237.6	475.3	89.5	479.3
x	2	-235.4	470.8	85.0	474.8
$x + f$	3	-235.3	470.6	84.8	476.6
saturation	100	-192.9	385.8	0.0	585.8

AIC: A (or Akaike) information criterion

kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 18 / 44





統計学的な検定 そして、その非対称性

モデル選択 と 統計学的検定 は その目的がぜんぜんちがう

kubostat2017d (<http://goo.gl/76c41>) 統計モデリング入門 2017 (d) 2019-07-29 26 / 44

統計学的な検定 そして、その非対称性

目的?

モデル選択: よい予測をするモデルの探索

統計学的検定: 帰無仮説の排除

kubostat2017d (<http://goo.gl/76c41>) 統計モデリング入門 2017 (d) 2019-07-29 27 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test

Null hypothesis  Alternative hypothesis 

帰無仮説 $glm(y \sim 1)$ is better!

対立仮説 $glm(y \sim x)$ is better!

VS

どうでもいい
… 興味ない…

重要！これを主張したい！

非対称性 asymmetry?

kubostat2017d (<http://goo.gl/76c41>) 統計モデリング入門 2017 (d) 2019-07-29 28 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test

Null hypothesis  Alternative hypothesis 

帰無仮説 $glm(y \sim 1)$ is better!

対立仮説 $glm(y \sim x)$ is better!

VS

test! 

(if ...) reject 棄却  support 支持

非対称性 asymmetry?

kubostat2017d (<http://goo.gl/76c41>) 統計モデリング入門 2017 (d) 2019-07-29 29 / 44

統計学的な検定 (Neyman-Pearson framework)

statistical test

Null hypothesis  Alternative hypothesis 

帰無仮説 $glm(y \sim 1)$ is better!

対立仮説 $glm(y \sim x)$ is better!

VS

test! 

(if ...) NOT reject  Say Nothing!?

非対称性 asymmetry?

kubostat2017d (<http://goo.gl/76c41>) 統計モデリング入門 2017 (d) 2019-07-29 30 / 44

統計学的な検定 そして、その非対称性

また同じ例題 The same example, again

D: deviance

個体 i

種子数 y_i

体サイズ x_i

seed number y_i

x model

constant λ

$D_2 = 470.8$

$D_1 = 475.3$

body size x_i

(施肥処理は無視!)

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 31 / 44

統計学的な検定 そして、その非対称性

検定統計量 $\Delta D_{1,2}$

difference in deviance $\Delta D_{1,2} = D_1 - D_2 = 4.51 \approx 4.5$

likelihood ratio? $-\log \frac{L_1^*}{L_2^*} = \log L_1^* - \log L_2^*$

model	k	$\log L^*$	Deviance $-2 \log L^*$	
constant λ	1	-237.6	$D_1 = 475.3$	帰無仮説
x	2	-235.4	$D_2 = 470.8$	対立仮説

検定の非対称性: 帰無仮説はゴミあつかい
.....にもかかわらず、帰無仮説だけをしつこく調べる

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 32 / 44

統計学的な検定 そして、その非対称性

帰無仮説のつくりかた

対立仮説の中に帰無仮説がある (ネストした関係)

- カウントデータ $\{y_i\}$ は平均である λ_i のポアソン分布に従う
- 対立仮説の一例: $\log \lambda_i = \beta_1 + \beta_2 x_i$
- ネストした 帰無仮説: $\log \lambda_i = \beta_1$ (切片だけのモデル)

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 33 / 44

統計学的な検定 そして、その非対称性

検定の目的: 帰無仮説 の棄却

帰無仮説は	「めったにない差」 (帰無仮説を棄却)	「よくある差」 (棄却できない)
真のモデルである	第一種の過誤	(問題なし)
真のモデルではない	(問題なし)	第二種の過誤

	significant	not significant
is ...	(Reject)	(Not reject)
TRUE	Type I error	(no problem)
NOT true	(no problem)	Type II error

検定の非対称性: 第一種の過誤だけに注目

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 34 / 44

統計学的な検定 そして、その非対称性

$\Delta D_{1,2}$ の分布を生成: ブートストラップ尤度比検定

帰無仮説 が真のモデルであるとしよう!

帰無仮説が真の統計モデル
ということにしてしまう
($\beta_1 = 2.06$ のポアソン分布)

評価用データに constant λ と x model をあてはめて逸脱度差 $\Delta D_{1,2}$ の分布を予測

$\Delta D_{1,2}$ $\Delta D_{1,2}$ $\Delta D_{1,2}$ \dots

△ △ △ \dots

帰無仮説のモデルから新しいデータをたくさん生成する

あてはまりの良さ評価用のデータ (多数)

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 35 / 44

統計学的な検定 そして、その非対称性

How to generate $\Delta D_{1,2}$ under is TRUE?

```
> d$y.rnd <- rpois(100, lambda = mean(d$y))
> fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
> fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
> fit1$deviance - fit2$deviance
```

- rpois() によるポアソン乱数の生成 (架空データ)
- 架空データを使って glm() あてはめ

kubostat2017d (<http://goo.gl/76c4i1>) 統計モデリング入門 2017 (d) 2019-07-29 36 / 44

統計学的な検定 そして、その非対称性

あらかじめ棄却域を決めておく

たとえば 5% とか?

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 37 / 44
```

統計学的な検定 そして、その非対称性

A random $\Delta D_{1,2}$ generator in R

```
get.dd <- function(d) # データの生成と逸脱度差の評価
{
  n.sample <- nrow(d) # データ数
  y.mean <- mean(d$y) # 標本平均
  d$y.rnd <- rpois(n.sample, lambda = y.mean)
  fit1 <- glm(y.rnd ~ 1, data = d, family = poisson)
  fit2 <- glm(y.rnd ~ x, data = d, family = poisson)
  fit1$deviance - fit2$deviance # 逸脱度の差を返す
}
pb <- function(d, n.bootstrap)
{
  replicate(n.bootstrap, get.dd(d))
}
```

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 38 / 44
```

統計学的な検定 そして、その非対称性

Generated distribution of $\Delta D_{1,2} = D_1 - D_2$

(R code is in the next page)

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 39 / 44
```

統計学的な検定 そして、その非対称性

$\text{Probability}\{\Delta D_{1,2} \geq 4.5\} = \frac{38}{1000} = 0.038$

```
> source("pb.R") # reading "pb.R" text file
> dd12 <- pb(d, n.bootstrap = 1000)
> hist(dd12, 100) # to plot histogram
> abline(v = 4.5, lty = 2)
> sum(dd12 >= 4.5)
[1] 38
```

so-called “P-value” is 0.038.

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 40 / 44
```

統計学的な検定 そして、その非対称性

In this case, 帰無仮説 is rejected

So we can state that 対立仮説 can be accepted.
x model is better than constant λ .

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 41 / 44
```

統計学的な検定 そして、その非対称性

In case that $P > 0.05 \dots ?$

何も結論できない

λ 一定のモデルが良いとは言えない

検定の非対称性: 帰無仮説 はけっして受容されない

```
kubostat2017d (http://goo.gl/76c4i) 統計モデリング入門 2017 (d) 2019-07-29 42 / 44
```

